

**Implementación de redes neuronales para detectar y corregir artefactos en imágenes de tomografía computarizada: retos y oportunidades**

Claudia Helena Vargas Martínez

Laura Nataly Laitón Amado

Michael Daniel Castiblanco Chacón

Nilsa Luzdari Guerrero Diaz

Asesor

Edna Rocío Jamaica Guio

Universidad Nacional Abierta y a Distancia - UNAD

Escuela de Ciencias de la Salud - ECISA

Tecnología en Radiología e Imágenes Diagnósticas

Mayo de 2025

## **Agradecimientos**

La dedicación y la perseverancia son sin duda alguna la clave del éxito, agradecemos inicialmente a Dios, quien nos ha brindado la sabiduría y guiado por un camino maravilloso lleno de retos, aprendizajes y oportunidades, a nuestras familias quienes estuvieron en primera fila creyendo en nosotros, dándonos apoyo incondicional cuando sentimos que no podíamos avanzar más, por su amor, comprensión y motivación constante, a los amigos que nos abrazaron justo cuando lo necesitábamos y nos dieron una palabra de aliento.

A nuestra estimada directora y asesora Edna Rocío Jamaica Guio por su compromiso, dedicación y aprendizaje, brindándonos orientación en todo momento para lograr nuestro objetivo, superando obstáculos y desafíos que nos harán mejores profesionales cada día.

A nuestros compañeros a lo largo de toda la carrera que de alguna manera nos enseñaron a fortalecer conocimientos, actitudes y comportamientos, quedándonos con todo lo positivo.

A nuestro equipo de trabajo Michael Daniel Castiblanco Chacón, Nilsa Luzdari Guerrero Díaz, Claudia Helena Vargas Martínez, Laura Nataly Laiton Amado donde fuimos unidos, constantes y dedicados en cada fase del proceso para lograr un resultado único y de gran enseñanza, finalmente y no menos importante a la Universidad Nacional Abierta y a Distancia (UNAD), que nos permite seguir soñando y avanzando profesionalmente.

## Resumen

Los artefactos y artificios son elementos claves que pueden afectar negativamente la calidad de las imágenes de tomografía computarizada (TC), estos incluyen todo tipo de degradación la cual puede ser causada por diversos factores como movimientos del paciente, materiales metálicos, borrosidad, imágenes fantasmas, deformación de las estructuras internas y distorsión de la imagen, generando diagnósticos erróneos. Por lo que, la reducción o eliminación de artefactos es una tarea compleja. En este contexto, el estudio de redes neuronales, las cuales están inspiradas en el funcionamiento de una red neuronal humana, se han convertido en una herramienta de gran utilidad en la detección significativa de artefactos en imágenes de tomografía computarizada (TC), presentando una solución innovadora de gran impacto, estas tienen la capacidad de aprender y organizar patrones complejos en las imágenes además de distinguir entre artefactos y estructuras anatómicas reales, lo que podría mejorar significativamente la calidad de las imágenes y, por ende, la precisión diagnóstica. La revisión literaria demuestra que la aplicación de redes neuronales en TC puede reducir de forma significativa la presencia de artefactos, mejorar la precisión diagnóstica y optimizar los flujos de trabajo en radiología. Así mismo, han demostrado ser de gran utilidad para la detección temprana de enfermedades y la clasificación automática de hallazgos. No obstante, persisten retos importantes, como la necesidad de bases de datos extensas y representativas, la interpretabilidad de los modelos y la integración segura en el entorno hospitalario, lo que permitirá aprovechar al máximo las oportunidades que ofrecen las redes neuronales en TC.

**Palabras Clave:** tomografía computarizada, redes neuronales, artefactos, artificios, calidad de la imagen, clasificación automática.

## Abstract

Artifacts and artifices are key elements that can negatively affect the quality of computed tomography (CT) images. These include all types of degradation that can be caused by various factors such as patient movement, metallic materials, blurriness, ghost images, deformation of internal structures, and image distortion, leading to erroneous diagnoses. Therefore, the reduction or elimination of artifacts is a complex task. In this context, the study of neural networks, which are inspired by the functioning of the human neural network, has become a highly useful tool for the significant detection of artifacts in computed tomography (CT) images, presenting an innovative and impactful solution. These networks have the ability to learn and organize complex patterns in images, as well as distinguish between artifacts and real anatomical structures, which could significantly improve image quality and, consequently, diagnostic accuracy. The literature review shows that the application of neural networks in CT can significantly reduce the presence of artifacts, improve diagnostic accuracy, and optimize workflows in radiology. Likewise, they have proven to be very useful for the early detection of diseases and the automatic classification of findings. However, important challenges remain, such as the need for extensive and representative databases, model interpretability, and secure integration into the hospital environment, which will allow maximizing the opportunities offered by neural networks in CT.

**Keywords:** computed tomography, neural networks, artifacts, artifices, image quality, automatic classification.

## Tabla de Contenido

Introducción .....	11
Planteamiento del Problema .....	13
Justificación .....	15
Objetivos .....	18
Objetivo General .....	18
Objetivos Específicos.....	18
Marco Teórico.....	19
Tomografía Computarizada .....	19
Tomógrafo y las Unidades Hounsfield .....	20
Evolución de los Equipos de TC.....	23
¿Qué son Artefactos o Artificios?.....	24
Artefactos en Imágenes Médicas .....	24
Artefactos por Movimiento del Paciente .....	26
Penumbra Geométrica.....	26
Endurecimiento del Haz de Rayos .....	27
Cuerpos Extraños e Implementos Médicos de Alta Densidad.....	28
Artefactos por Entradas de Flujo .....	29
Volumen Parcial Promedio.....	30
Proyección Incompleta.....	30
Artefacto Escalonado .....	31
Artefacto en “Cebra”.....	32
Artefactos en Molino de Viento.....	32

Redes Neuronales.....	33
¿Qué es una Red Neuronal? .....	33
Historia.....	34
Ventajas.....	35
Aprendizaje Adaptativo .....	36
Autoorganización.....	36
Tolerancia a Fallos .....	37
Operaciones en Tiempo Real .....	37
Fácil Inserción Dentro de la Tecnología Existente .....	37
Redes Neuronales en Tomografía Computarizada (TC).....	38
Multilayer Perceptron (MLP) .....	39
Red Neuronal de Hopfield .....	39
Self-organizing Maps (SOMs).....	40
Deep Learning (DL).....	41
Deep Multilayer Perceptron (DMLP) .....	41
Deep Auto-encoder (DAE) .....	42
Recurrent Neural Network (RNN).....	42
Restricted Boltzmann Machine (RBM) .....	43
Convolutional Neural Network (CNN).....	44
Metodología .....	45
Enfoque Cualitativo .....	46
Enfoque Descriptivo .....	46
Obtención de Datos.....	46

Criterios de Inclusión.....	47
Limitaciones del Estudio.....	47
Análisis de Datos .....	47
Parámetros Legales .....	48
Resultados .....	49
Conclusiones .....	58
Referencias Bibliográficas .....	61

## Lista de Tablas

<b>Tabla 1</b> <i>Clasificación de movimientos</i> .....	25
<b>Tabla 2</b> <i>Tipos de artefactos en TC</i> .....	49
<b>Tabla 3</b> <i>Comparación del cerebro humano vs computador convencional</i> .....	50
<b>Tabla 4</b> <i>Retos y oportunidades</i> .....	58

## Lista de Figuras

<b>Figura 1</b> <i>Primer prototipo de escáner clínico</i> .....	21
<b>Figura 2</b> <i>Escala de UH</i> .....	22
<b>Figura 3</b> <i>Valores en UH de los órganos</i> .....	22
<b>Figura 4</b> <i>Evolución de la cobertura de los equipos multidetector con el aumento de las filas activas disponibles</i> .....	24
<b>Figura 5</b> <i>Artefactos y artificios frecuentes en tomografía computada</i> .....	25
<b>Figura 6</b> <i>TC de macizo craneofacial, en ventana ósea, corte axial</i> .....	26
<b>Figura 7</b> <i>TC de cerebro, corte axial</i> .....	27
<b>Figura 8</b> <i>TC de cerebro, corte axial</i> .....	28
<b>Figura 9</b> <i>Plano abdominal alto, corte axial</i> .....	29
<b>Figura 10</b> <i>TC de tórax con contraste endovenoso, corte axial en ventana mediastino</i> .....	29
<b>Figura 11</b> <i>TC de cerebro, corte axial</i> .....	30
<b>Figura 12</b> <i>TC de tórax, corte axial en ventana mediastino</i> .....	31
<b>Figura 13</b> <i>TC de cráneo, reconstrucción 3D, en ventana ósea</i> .....	31
<b>Figura 14</b> <i>TC de cuello, en reconstrucción multiplanar, corte coronal, con contraste endovenoso</i> .....	32
<b>Figura 15</b> <i>TC de abdomen, corte axial</i> .....	33
<b>Figura 16</b> <i>Las neuronas y las conexiones entre ellas (sinapsis) constituyen la clave para el proceso de la información</i> .....	34
<b>Figura 17</b> <i>Esquema de una red neuronal</i> .....	38
<b>Figura 18</b> <i>Multilayer perceptron (MLP)</i> .....	39
<b>Figura 19</b> <i>Red neuronal de Hopfield</i> .....	40

<b>Figura 20</b> <i>Self-organizing map (SOM)</i> .....	39
<b>Figura 21</b> <i>Red neuronal profunda (DNN)</i> .....	41
<b>Figura 22</b> <i>Deep auto-encoder (DAE)</i> .....	42
<b>Figura 23</b> <i>Red neuronal recurrente (RNN)</i> .....	43
<b>Figura 24</b> <i>Máquina restringida de Boltzmann (RBM)</i> .....	44
<b>Figura 25</b> <i>Red neuronal convolucional (CNN)</i> .....	44
<b>Figura 26</b> <i>Proceso de los métodos de DL en diversos dominios</i> .....	51
<b>Figura 27</b> <i>Modelo AD2 Vs observador humano</i> .....	53

## Introducción

En la medicina moderna, la precisión y confiabilidad de las imágenes diagnósticas son esenciales para la toma de decisiones clínicas oportunas. Por lo que el uso de la tomografía computarizada (TC) se ha convertido en una de las herramientas más eficaces para el diagnóstico médico moderno, permitiendo la visualización detallada de estructuras anatómicas del cuerpo. Sin embargo, la calidad de las imágenes obtenidas se puede ver seriamente comprometida debido a la presencia de artefactos, los cuales distorsionan la visualización de las imágenes obtenidas, dificultando la interpretación clínica, conduciendo a diagnósticos errados, así como la necesidad de repetir estudios, aumentando la exposición a radiación. De manera que la corrección y detección de estos artefactos representan un desafío crucial para la radiología contemporánea.

Durante los últimos años, el avance de la inteligencia artificial y, especialmente de las redes neuronales, ha abierto nuevas oportunidades para abordar este problema. Su arquitectura, inspirada en el funcionamiento del cerebro humano, demuestran una notable capacidad para aprender patrones complejos y realizar tareas de procesamiento de imágenes con una precisión superior en comparación con los métodos tradicionales, de manera que su aplicación en la reconstrucción, segmentación y mejora de imágenes médicas ha permitido tanto reducir el ruido y los artefactos, como optimizar la calidad diagnóstica de las imágenes incluso en condiciones de baja dosis de radiación.

El uso de redes neuronales para detectar y corregir artefactos en imágenes de TC conlleva retos técnicos y metodológicos significativos, como lo es la necesidad de grandes volúmenes de datos etiquetados, variabilidad de los artefactos según el tipo de equipo y paciente, y la validación clínica de los algoritmos desarrollados. Por otro lado, las oportunidades que ofrece

esta tecnología son incluso relevantes, desde mejorar la precisión diagnóstica, reducción de la exposición a radiación, hasta la optimización de los recursos en los servicios de salud.

Este trabajo explora el estado actual, los desafíos y el futuro panorama del uso de redes neuronales en la detección y corrección de artefactos en imágenes de tomografía computarizada, comparando tanto los avances alcanzados como las barreras que aún deben superarse para su integración efectiva en la práctica clínica diaria.

## Planteamiento del Problema

La tomografía computarizada (TC) es una técnica de diagnóstico que desde sus inicios ha facilitado la evaluación y visualización de diversas patologías, sin embargo, a pesar de los grandes desarrollos tecnológicos, esta técnica aún presenta problemas constantes como la presencia de artefactos o artificios durante la realización de estudios diagnósticos, haciendo que las imágenes obtenidas no tengan una calidad óptima, generando diagnósticos poco confiables o en definitiva no sea posible realizar la lectura de las mismas y por ende se deba repetir el estudio exponiendo al paciente a altas dosis de radiación ionizante.

De igual manera, estos artefactos pueden ser generados por diversos factores como lo son: movimientos del paciente, presencia de objetos metálicos, mala calibración de los detectores, o uso de medios de contraste inadecuados. Por lo tanto, la identificación y corrección de estos artefactos son fundamentales para garantizar que las imágenes obtenidas sean lo más precisas y de esta manera asegurar un diagnóstico correcto y, por ende, un tratamiento efectivo.

Asimismo, han ocurrido grandes avances en los equipos de tomografía computarizada (TC) desde la cantidad de detectores hasta el tiempo de exposición a la radiación de los pacientes, sin embargo, una gran desventaja se basa en la calidad de la imagen debido a diversas causas, ocasionando imágenes alteradas y/o inaceptables para un diagnóstico oportuno. Es por ello, que se busca avanzar en tecnologías que ayuden a mejorar la calidad de la imagen detectando a tiempo cualquier artefacto u obstáculo que interfiera en ella; según Carrizales et al., (2024) “se han logrado muchos avances en la mejora de las imágenes 4DCT mediante el uso de técnicas de detección y corrección de artefactos” (p. 1098).

Por consiguiente, el uso de redes neuronales para la detección automática de artefactos en imágenes de tomografía computarizada (TC) se presenta como una solución innovadora, cuya

capacidad de aprender patrones complejos en las imágenes y distinguir entre artefactos y estructuras anatómicas reales, puede mejorar significativamente la calidad de las imágenes y la precisión diagnóstica. Sin embargo, este enfoque requiere una revisión exhaustiva de la literatura existente sobre el tema, para comprender cómo las redes neuronales pueden ser entrenadas y validadas para este propósito específico. Además, es importante analizar los desafíos técnicos y éticos involucrados en el uso de algoritmos de aprendizaje automático en el contexto de la imagenología médica.

Los estudios de TC permiten realizar diagnósticos de una gran amplia variedad de patologías, sin embargo, como ya se ha mencionado anteriormente, la presencia de artefactos generados por diversos factores puede impedir un diagnóstico oportuno y, por tanto, someter al paciente a altas dosis de radiación ionizante. Ante esta problemática, se propone la implementación de redes neuronales para detectar y corregir de forma automática los artefactos, con el objetivo de mejorar la calidad y elevar la precisión diagnóstica en TC.

Con el fin de dar respuesta a la pregunta problema: ¿De qué manera la implementación de redes neuronales en tomografía computarizada puede mejorar la detección y corrección automática de artefactos, optimizando la calidad de imagen y reduciendo la exposición del paciente a radiación ionizante, y cuáles son los retos técnicos y éticos que esto implica?, se llevará a cabo una investigación exhaustiva de fuentes literarias, artículos científicos y académicos, y otras fuentes pertinentes publicadas entre el año 2019 y la actualidad.

## Justificación

El propósito de la presente investigación, es determinar las causas e impactos que llevan el uso de redes neuronales para la detección y reducción de artefactos en imágenes de Tomografía Computarizada, mejorando la precisión diagnóstica, minimizando errores interpretativos y reduciendo la exposición del paciente a radiación ionizante al evitar repeticiones innecesarias del estudio. La investigación busca contribuir al conocimiento actual en el campo de la imagenología médica mediante una revisión crítica de los avances recientes y las oportunidades que brinda la inteligencia artificial, especialmente las redes neuronales, en la optimización de procesos diagnósticos.

El procesamiento de imágenes digitales es un área de investigación de gran interés en la comunidad académica moderna, debido a su contribución vital al campo médico y a la humanidad en su conjunto. Farhan et al., (2024) destacan que estas técnicas se utilizan cada vez más en el ámbito sanitario para extraer información útil sobre enfermedades críticas a partir de imágenes médicas digitales como TC, rayos X, PET y MRI, lo que ayuda a detectar la enfermedad en sus primeras etapas y aumentan las posibilidades de supervivencia de los pacientes.

Teniendo en cuenta que las dos modalidades de imágenes más comunes son la tomografía computarizada (TC) y la resonancia magnética (RM), puesto que han demostrado una enorme utilidad en el diagnóstico de diversas patologías. Paudyal et al., (2023) señalan que “la aparición de herramientas basadas en inteligencia artificial (IA) en las imágenes médicas han sido motivadas por el deseo de una mayor eficiencia y eficacia en la atención clínica” (p. 9). Si bien, es muy alentador que exista un número creciente de nuevas herramientas de IA para tareas

específicas en las imágenes, el esfuerzo por abordar los desafíos clave para la implementación por parte de la comunidad mundial de imágenes aún no se ha abordado adecuadamente.

La reducción o eliminación de artefactos es una tarea complicada cuando la física de creación de artefactos no está bien modelada matemáticamente. Una de esas situaciones son los artefactos metálicos en la tomografía computarizada con rayos X, cuando el material metálico es desconocido y el espectro de rayos X es amplio. (Zeng, 2023, p. 9).

Por lo anterior, se hace imprescindible en esta investigación identificar las consecuencias de la detección y reducción de artefactos en imágenes de Tomografía Computarizada, mejorando la precisión diagnóstica. Tener en cuenta las causas, es un factor esencial donde se utiliza una red neuronal para actuar como objetivo en la reducción iterativa de artefactos cuando se desconoce el modelo del artefacto.

La evolución tecnológica alrededor de la TC, ha permitido que se puedan realizar una gran variedad de estudios por imágenes facilitando la visualización detallada de estructuras anatómicas y el diagnóstico de condiciones potencialmente mortales, no obstante, aunque la técnica de adquisición sea la más adecuada, las imágenes obtenidas pueden contener artefactos o artificios ocasionados por movimientos del paciente, presencia de objetos metálicos o problemas técnicos en los detectores del equipo, los cuales, reducen la calidad de las imágenes obtenidas, generando diagnósticos erróneos, ocultación de patologías importantes o volviéndolas completamente inservible para el diagnóstico, teniendo que repetir el estudio y sometiendo al paciente a una doble dosis de radiación ionizante.

En comparación con los métodos tradicionales de detección y corrección de artefactos, pueden ser de difícil visualización y pocos efectos, necesitando la intervención manual de médicos especializados, lo que puede generar errores humanos. Asimismo, la demanda de

imágenes de alta calidad para diagnósticos precisos aumenta la necesidad de desarrollar nuevas tecnologías.

Por lo tanto, el propósito de la investigación es reconocer como a partir del uso de redes neuronales se pueda identificar y corregir automáticamente artefactos en las imágenes diagnósticas, presentando una solución prometedora con el fin de innovar el campo de la TC.

## **Objetivos**

### **Objetivo General**

Realizar una investigación profunda de la literatura disponible acerca del uso de redes neuronales en tomografía computarizada para la detección y corrección de artefactos, así como su impacto en la precisión diagnóstica y reducción a la exposición a radiación ionizante.

### **Objetivos Específicos**

Identificar los diferentes artefactos en las imágenes de tomografía computarizada y la frecuencia en que ocurren los mismos.

Reconocer las diferentes redes neuronales usadas en tomografía computarizada, así como su enfoque práctico.

Analizar los últimos avances en inteligencia artificial que se utilizan para mejorar las imágenes médicas, enfocándose en las redes neuronales convolucionales.

Determinar las ventajas y desventajas del uso de redes neuronales en tomografía computarizada (TC).

## Marco Teórico

### Tomografía Computarizada

La tomografía computarizada (TC) hace parte de una de las técnicas por imagen más eficientes que existe en la actualidad como método diagnóstico para identificar diferentes patologías. Luego del descubrimiento de los rayos x por Wilhelm Rontgen en el año 1895 existieron destacados ingenieros curiosos que analizaban, indagaban y buscaban comprender más allá de los rayos x convencionales, uno de ellos fue Godfrey Hounsfield quien se inventó la tomografía computarizada a partir de proyecciones radiográficas para los años 70, convirtiendo esta modalidad en una de las técnicas más detalladas e innovadoras a través del tiempo.

Inicialmente los tomógrafos fueron creados con un solo detector, estos median la energía que los fotones de Rx emitían al ser impactados al detector, transformando dicha energía en una energía eléctrica que llega al ordenador en forma de imagen en escala de grises, para entonces los estudios eran limitados ya que el tiempo de adquisición eran una exageración y así mismo la cantidad de dosis recibida, por dicha razón, se seguía investigando diferentes conceptos que ayudaran a mejorar desde el tiempo de adquisición hasta la cantidad de detectores.

En la actualidad, esto ha venido mejorando ya que se cuenta con tomógrafos de 256 detectores, siendo de estado sólido y semiconductores y no de cristal de centelleo modificando tiempos, dosis, calidad de imagen y costos. según Bustos (2022), “se adelantan trabajos sobre el desarrollo de nuevas técnicas para los dispositivos en tomografía axial computada (TAC), enfocados en áreas de investigación tales como, disminución de dosis, ergonomía de la tecnología, optimización de imágenes, entre otros”.

### ***Tomógrafo y las Unidades Hounsfield***

Una vez identificada la radiología convencional como una de las principales herramientas de diagnóstico por imagen se conocieron también sus limitaciones y con ello la necesidad de avanzar más allá de una imagen convencional de rayos x, ya que se buscaba separar en forma cuantitativa las diferentes densidades de las estructuras exploradas por el haz de rayos x.

Hounsfield aplicó sus conocimientos logrados y el gusto por los computadores para crear un escáner que permitiera visualizar diferentes órganos y tejidos donde utilizó el giro del tubo de rayos X en un eje axial, procesando la información a través de detectores y amplificadores de mayor sensibilidad a diferencia de la imagen que se lograba con radiología convencional.

Para Bosch (2004), la tomografía computada introduce el cambio ya que puede medir la atenuación o absorción del haz de rayos cuando pasa a través de secciones del cuerpo y lo hace desde diferentes ángulos. Con estas mediciones, los computadores pueden reconstruir imágenes del interior del cuerpo. El paradigma fue comprender, que, al escanear un objeto desde muchos ángulos, era posible extraer toda la información contenida en él. (p. 184).


Se evidencio de inmediato los avances tecnológicos desde la toma de una simple imagen por radiología convencional que mostraba solo los huesos sin poder diferenciar detalladamente los tipos de tejido a lograr tomar múltiples imágenes en corte axial donde se podía examinar el cráneo y lo que habita dentro de él.

Así fue como Godfrey construyo su primer prototipo de escáner que solo permitía escanear el cerebro, pero viendo los resultados clínicos favorables rápidamente se fueron construyendo nuevos escáneres con notables avances tanto tecnológicos como físicos del propio

equipo, permitiendo mejorar el tiempo de exposición, dosis, entre otros, así mismo se logra explorar el resto del cuerpo mejorando la calidad de la imagen.

### **Figura 1**

*Primer prototipo de escáner clínico*




*Nota.* Tomado de *SIR Godfrey Newbold Hounsfield y la tomografía computada, su contribución a la medicina moderna*, por E. Bosch, 2004, *Revista Chilena de Radiología*, 10(4), pp. 183–185. Copyright 2004 Sociedad Chilena de Radiología.

La atenuación de los tejidos fue representada a través de una escala de -1000 a +1000 llamada escala de Unidades Hounsfield (UH), en honor a quien evoluciono la imagen diagnóstica a través del escáner. Las imágenes de TC representan la reconstrucción del coeficiente de atenuación de los tejidos al paso de los rayos X. Este valor se obtiene a partir de la medida de la radiación emitida que logra atravesar los tejidos y llegar a los detectores. La diferencia entre la intensidad de la radiación emitida y la que llega al detector depende del coeficiente de atenuación y del grosor del material interpuesto en el trayecto del haz, Armiñana et al., (2023), así es como podemos diferenciar entre cantidades de niveles de grises que la escala de

Hounsfield brinda, calculando la atenuación del haz de rayos x que atraviesa los órganos y tejidos.

## Figura 2

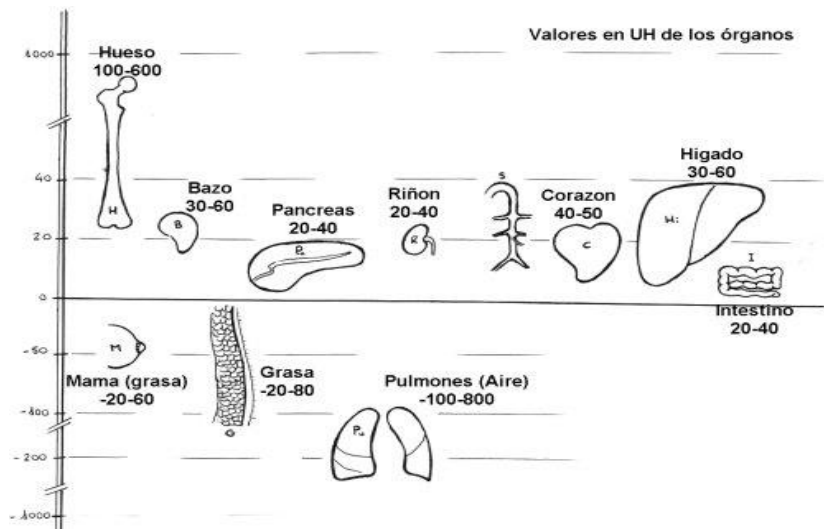
Escala de UH



Nota. Tomado de *La escala de Hounsfield. Modulo técnica radiológica 1 Guanacaste*. Por Pérez, L. (2012).

## Figura 3

Valores en UH de los órganos



Nota. Tomado de *La escala de Hounsfield. Modulo técnica radiológica 1 Guanacaste*. Por Pérez, L. (2012).

### *Evolución de los Equipos de TC*


Como refieren Calzado y Geleijns (2010), el primer tomógrafo fue presentado en 1972, contaba con un solo detector, el haz del rayo era estrecho y de poca cobertura, lo que hacía que la camilla se trasladara en pasos cortos para la obtención de imagen de cada corte, en 1974 se introduce la segunda generación la cual sigue realizando movimientos de traslación y rotación cuenta con varios tubos de rayos X con angulación, cada uno con su detector, obteniendo más proyecciones por movimiento disminuyendo el tiempo del estudio.

Bosch (2004) señala que, entre 1976 y 1979 llega la tercera generación introduciendo la rotación continua del tubo y el detector sin traslación, de modo que el haz del rayo se vuelve más ancho tipo abanico en un equipo en forma de arco, de 1980 a 1983 la cuarta generación cuenta con la circunferencia total de detectores la cual esta fija alrededor del Gantry y solo se desplaza el tubo de rayos X. sin embargo la mayoría de los equipos actuales están basados en el modelo de tercera generación.

Calzado y Geleijns (2010) subrayan que la tomografía helicoidal o espiral llega en 1989 a 1990 en este escáner la mesa se mueve de forma continua durante el movimiento del tubo de RX, creando un giro en espiral alrededor del paciente permitiendo adquisiciones en menos tiempo. Entre 1998 y 2000 llegaron los tomógrafos multicortes o multidetector con hasta 320 canales, facilitando la captación de múltiples cortes de una sola vez, aumentando la resolución de imagen y redujo el tiempo de exposición. Hoy día se cuenta con equipos de más de 60.000.000 de cortes, realizando estudios más complejos y de alta precisión en segundos.

## Figura 4

*Evolución de la cobertura de los equipos multidetector con el aumento de las filas activas disponibles*



*Nota.* Adaptado de *Diagnostic Imaging for the Radiologic Technologist*, por A. Calzado y Geleijns, 2010. Copyright 2010 por Springer.

## ¿Qué son Artefactos o Artificios?

Sartori et al., (2015) indican que:

Un artefacto o artificio se define como una distorsión, adición o error en una imagen que no tiene correlación en el sujeto o región anatómica estudiada. Como término, proviene de las palabras latinas *artis* (artificial) y *actum* (efecto), y se refiere a un efecto artificial que altera la calidad y fidelidad de una imagen, pudiendo encubrir una patología o crear hallazgos falsos.


### *Artefactos en Imágenes Médicas*

Los artefactos de movimiento incluyen todo tipo de degradación de la imagen causada por los movimientos del paciente. Estos artefactos se presentan en diversas formas, como

borrosidad, vetas, imágenes fantasmas, deformación de las estructuras internas o distorsión de la imagen.

### Figura 5

*Artefactos y artificios frecuentes en tomografía computada*



*Nota.* Artefacto por movimiento del paciente. Tomada de *Artefactos y artificios frecuentes en TC y RM* (p. 193). por Sartori et al., 2015., *Revista Argentina De Radiología*.

### Tabla 1

*Clasificación de movimientos*

Tipo de movimientos	Descripción
No controlados	Deglución Movimientos oculares Temblor por discomfort-inquietud Movimientos por dolor
Fisiológicos	Movimientos respiratorios Latidos cardíacos Flujo circulante (vascular, linfático, líquido cefalorraquídeo)

*Nota.* Sartori et al., 2015., *Revista Argentina De Radiología*. *Artefactos y artificios frecuentes en TC y RM* (p. 193).


Haciendo énfasis en los diferentes factores que interfieren en la calidad de una imagen podemos hablar sobre diversos artificios o artefactos como lo son:

### ***Artefactos por Movimiento del Paciente***

Estos se producen por el movimiento normal de cada órgano del cuerpo como la respiración, la deglución, el peristaltismo, los latidos del corazón, entre otros. Se manifiestan durante el escaneo, por lo que es necesario suspender la respiración para estudios a nivel de tórax. Sartori et al., (2015) menciona que “se aprecian como bandas blancas y negras intercaladas, manchas o lunares negros, pérdida de la resolución, desdoblamiento de los contornos de las diferentes estructuras o distorsión de la anatomía”.

### **Figura 6**

*TC de macizo craneofacial, en ventana ósea, corte axial*



*Nota.* Se visualiza mala calidad en la imagen debido a un artefacto generado por el movimiento del paciente, generando una distorsión en la anatomía normal. Tomado de *Artefactos y artificios frecuentes en TC y RM* (p. 193). Sartori et al., 2015., Revista Argentina De Radiología.


### ***Penumbra Geométrica***

Esta se basa en la inadecuada alineación de los rayos x del tubo en relación con los detectores, produciendo imágenes borrosas con resolución espacial limitada. Sartori et al., (2015)

mencionan que “Un correcto y periódico mantenimiento y calibración del tomógrafo o una colimación secundaria eficaz reducen el efecto.”

### **Figura 7**

*TC de cerebro, corte axial*



*Nota.* Se observan múltiples anillos concéntricos (flecha) con aspecto de “rueda de carro”. Tomado de *Artefactos y artificios frecuentes en TC y RM* (p. 194). por Sartori et al., 2015., *Revista Argentina De Radiología*.

### ***Endurecimiento del Haz de Rayos***

Se origina por la absorción preferencial de los fotones de baja energía del rayo en los tejidos, principalmente sucede en el tejido óseo por su capacidad de atenuación. (Sartori et al., 2015).

**Figura 8**

*TC de cerebro, corte axial*




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

***Cuerpos Extraños e Implementos Médicos de Alta Densidad***

Dependen de instrumentos quirúrgicos que contengan algún tipo de metal, por ejemplo: las prótesis dentales, el material de osteosíntesis, aparatos de vigilancia, accesorios de ropa, incluso los medios de contraste, entre otros. Se reconoce porque el elemento genera un halo de absorción falsa en una o varias direcciones similares al rayo de sol. (Sartori et al., 2015).

### Figura 9

*Plano abdominal alto, corte axial*




*Nota.* Se evidencia un objeto metálico en la pared abdominal anterior del paciente, el cual corresponde a la vía de solución parenteral generando artefactos en forma de rayos de sol asociado a un elemento quirúrgico. Tomada de *Artefactos y artificios frecuentes en TC y RM* (p. 195). por Sartori et al., 2015., *Revista Argentina De Radiología*.

### *Artefactos por Entradas de Flujo*

Se genera a nivel de las venas axilar y subclavia en TC de tórax con contraste debido al corto tiempo transcurrido entre la administración del contraste y el inicio de la adquisición de la imagen (Sartori et al., 2015).

### Figura 10

*TC de tórax con contraste endovenoso, corte axial en ventana mediastino*




*Nota.* Artificio generado por el contraste en la región axilar derecha, a consecuencia de un escaneo precoz (flecha). Imagen tomada de *Artefactos y artificios frecuentes en TC y RM* (p. 196). por Sartori et al., 2015., *Revista Argentina De Radiología*.

### ***Volumen Parcial Promedio***

Ocurre cuando dos tejidos de diferente absorción ocupan el mismo vóxel; en este caso, la intensidad del pixel, corresponde al promedio de las densidades de las estructuras vóxel (Sartori et al., 2015).

### **Figura 11**

*TC de cerebro, corte axial*




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

### ***Proyección Incompleta***

Esta ocurre cuando una parte del paciente se encuentra fuera del área de interés, pero logra salir en el estudio, generando distorsiones en los bordes de la imagen. Se trata del llamado artefacto de desborde de campo, y se puede mitigar ajustando el campo de medida al volumen corporal del paciente (Sartori et al., 2015).

## Figura 12

*TC de tórax, corte axial en ventana mediastino*




*Nota.* Se evidencian líneas hipo e hiperdensas en horizontal (flechas) generando un arteficio porque el paciente no pudo elevar los brazos. Tomada de *Artefactos y artificios frecuentes en TC y RM* (p. 196). por Sartori et al., 2015., *Revista Argentina De Radiología*.

## Artefacto Escalonado

Generalmente sucede en las imágenes multiplanares o 3D reformateadas y se presenta en los bordes de la estructura estudiada como líneas superpuestas (Sartori et al., 2015).

## Figura 13

*TC de cráneo, reconstrucción 3D, en ventana ósea*



*Nota.* reconstrucción 3D de cráneo en la que se visualiza en el extremo superior del vertex del cráneo arteficio concéntrico y escalonado (flecha). Tomada de *Artefactos y artificios frecuentes en TC y RM* (p. 197). por Sartori et al., 2015., *Revista Argentina De Radiología*.

### ***Artefacto en Cebra***

Se visualizan como tenues rayas escalonadas, son más frecuentes en reconstrucciones multiplanares y 3D plano sagital o coronal, son causados por cortes gruesos durante la adquisición (Sartori et al., 2015).

### **Figura 14**

*TC de cuello, en reconstrucción multiplanar, corte coronal, con contraste endovenoso*




*Nota. se evidencian líneas horizontales superpuestas sobre la figura (flechas). Tomada de *Artefactos y artificios frecuentes en TC y RM* (p. 198). por Sartori et al., 2015., *Revista Argentina De Radiología*.*

### ***Artefactos en Molino de Viento***

Se presentan por el movimiento de la mesa en simultanea con el tubo de RX, la fila de detectores pasa por el área de interés y al reconstruir oscila entre las medidas de un solo detector y la interpolación de dos o más, al existir una diferencia entre estos se observará la imagen distorsionada (Sartori et al., 2015).

## Figura 15

*TC de abdomen, corte axial*



*Nota.* Artefacto en “remolino” impide la visualización normal del abdomen. Tomada de *Artefactos y artificios frecuentes en TC y RM* (p. 198). por Sartori et al., 2015., *Revista Argentina De Radiología*.

Existen innumerables factores que pueden ser causantes de artefactos que dañan una imagen diagnóstica, es por ello, que deben ser reconocidos y analizados para entender por qué se originan y buscar la solución de mejora a través algoritmos, procesos y modificación de parámetros del equipo que ayuden a mejorar la calidad de la imagen ya que ese es el principal objetivo, cabe destacar que los artefactos son el principal responsable de detectar patologías erróneas o encubrirlas en su defecto.

## Redes Neuronales


### ¿Qué es una Red Neuronal?

Según Matich (2001), existen varias formas de dar definición a las redes neuronales, pueden ser nuevas formas de computación basados en modelos biológicos, modelos matemáticos compuestos por un gran número de elementos procesales organizados en niveles o redes interconectadas masivamente en paralelo de elementos simples (usualmente adaptativos) y con

organización jerárquica, las cuales intentan interactuar con los objetos del mundo real de manera similar al sistema nervioso biológico.

### Figura 16

*Las neuronas y las conexiones entre ellas (sinapsis) constituyen la clave para el proceso de la información*



*Nota. Imagen tomada de Inteligencia Artificial, por O. Duarte, 2014, SlideServe.*

### Historia

La investigación de las redes neuronales inicia el 1936 con Alan Turing estudiando el cerebro viéndolo desde un enfoque computacional, sin embargo, fue a manos de Warren McCulloch neurofisiólogo y Walter Pitts, matemático, que en 1943 iniciaron la teoría acerca del trabajo neuronal en su publicación *Un Cálculo Lógico de la Inminente Idea de la Actividad Nerviosa*, donde modelaron una red neuronal simple mediante circuitos eléctricos.

Posteriormente, en 1949, Donald Hebb explica el proceso de aprendizaje desde el punto de vista psicológico, indicando que el aprendizaje ocurre cuando ciertos cambios en una neurona se activan, desarrollando una regla de como el aprendizaje ocurría, conservándose hasta hoy día como fundamento y base de las funciones de aprendizaje en redes neuronales. (Matich, 2001).

Ahora bien, en 1950, Karl Lashley en sus diversos ensayos, indicó que la información no era almacenada en forma centralizada en el cerebro, sino que era distribuida encima de él; el congreso de Dartmouth realizado en 1956, conocido como el nacimiento de la inteligencia artificial (AI). En 1957, Frank Rosenblatt desarrolló el Perceptron, siendo la red neuronal más antigua y por ende la más utilizada hoy día para aplicar en la identificación de patrones, este modelo tenía la capacidad de generalizar, o reconocer patrones similares a los aprendidos aun cuando no se le hubiesen presentado, sin embargo, no podía resolver ciertos problemas como clasificar clases no separables linealmente (Matich, 2001).

Asimismo, en 1969, Marvin Minsky y Seymour Papert casi producen la muerte de las redes neuronales, probando matemáticamente que Perceptrons no tenía la capacidad de resolver problemas medianamente fáciles como el aprendizaje no-lineal, siendo este igual al computacional, demostrando que era muy débil. No obstante, en 1974 Paul Werbos propuso la idea del algoritmo de aprendizaje de propagación hacia atrás (backpropagation), cuyo funcionamiento sería comprendido y aclarado en 1985. En este mismo año, John Hopfield provoca el renacimiento de las redes neuronales con su publicación “*Computación neuronal de decisiones en problemas de optimización*”. A partir de 1986, el panorama frente a las redes neuronales mejoró, generando el auge de investigaciones, desarrollos y numerosos trabajos centrados en el control, además de nuevos productos en el mercado como hardware y software (Matich, 2001).

### ***Ventajas***

Dado que el estilo de construcción de las redes neuronales presenta características similares a las del cerebro, algunas ventajas de su uso son, aprendizaje adaptativo,

autoorganización, tolerancia a fallos, operación en tiempo real y fácil inserción dentro de la tecnología existente (Matich, 2001).

### ***Aprendizaje Adaptativo***

Tienen la capacidad de realizar tareas a partir del entrenamiento por medio de ejemplos e ilustraciones, lo que las hace prácticas al disminuir la necesidad de generar modelos a priori y especificar funciones de distribución de probabilidad. Gracias a que son sistemas dinámicos autoadaptativos debido a la capacidad de aprendizaje de autoajuste de los elementos procesales o neuronas, cambian de manera constante para adaptarse a nuevas condiciones, al no necesitar algoritmos en la resolución de problemas durante el aprendizaje, las neuronas se ajustan de forma que se obtienen criterios específicos. Esta capacidad de adaptación es una de las características más atractivas de las redes neuronales (Matich, 2001).

### ***Autoorganización***

Usan la capacidad de aprendizaje adaptativo para organizar la información que reciben durante el aprendizaje, es decir, modifican la red neuronal completa para realizar una tarea u objetivo en específico. Al ser usada para reconocer ciertos patrones, autoorganizan la información que procesan, como señala Matich (2001), "por ejemplo, la red llamada backpropagation, creará su propia representación característica, mediante la cual puede reconocer ciertos patrones."

La autoorganización facilita a las redes neuronales dar una respuesta correcta cuando se les muestran datos o situaciones a las que no ha sido expuesta. Es un sistema que puede generalizar la entrada de datos para obtener una respuesta, ya que, cuando se debe solucionar un problema con una entrada no muy clara o incompleta facilita la solución (Matich, 2001).

### ***Tolerancia a Fallos***

Los sistemas informáticos tradicionales pierden funcionalidad con pequeños errores de memoria ya que el sistema de recuperación de datos almacena cada pieza en un espacio único, localizado y direccionable; en comparación con las redes neuronales, estas pueden tener fallos en su gran parte de neuronas y no tener una caída, lo que es posible ya que las redes distribuyen la información en las conexiones neuronales.

Así mismo, hay dos tipos de tolerancia a fallos, como son: fallos respecto a datos, donde las redes aprenden a reconocer patrones de ruido, distorsión o incompletos y fallos donde la red puede realizar su función con cierta degradación, incluso cuando se destruye parte de la red. En este caso, gran parte de las interconexiones entre nodos de la red tendrá valores en función de estímulos recibidos, generando patrones de salida que representa la información almacenada (Matich, 2001).

### ***Operaciones en Tiempo Real***

La mayoría de las áreas en las que se aplican las conexiones necesitan procesar datos de forma muy rápida, por lo que las redes neuronales resultan adecuadas debido a su capacidad para procesar en paralelo, para que esto suceda en tiempo real es necesario un ajuste mínimo en los pesos de las conexiones o entrenamiento (Matich, 2001).


### ***Fácil Inserción Dentro de la Tecnología Existente***

Una red se puede entrenar para realizar una tarea con las herramientas de computación existentes, sin embargo, en tareas más complejas que requieren de múltiples patrones necesita un sistema compuesto por varias redes; gracias a las herramientas computacionales avanzadas una red puede ser entrenada, probada, verificada y trasladada rápidamente a una implementación de hardware económica facilitando la integración de redes neuronales en aplicaciones específicas,

como el control dentro de sistemas existentes. De esta manera, las redes neuronales pueden mejorar sistemas de forma incremental, permitiendo evaluar cada paso antes de avanzar hacia un desarrollo más amplio (Matich, 2001).

**Figura 17**

*Esquema de una red neuronal*



*Nota.* Red neuronal constituida por neuronas interconectadas y arregladas en tres capas. Los datos ingresan por medio de la “capa de entrada”, pasan a través de la “capa oculta” y salen por la “capa de salida”. La capa oculta puede estar constituida por varias capas. Tomada de *Redes Neuronales: Conceptos Básicos y Aplicaciones*. (p. 12). por Matich, D., 2001., *Universidad Tecnológica Nacional, Facultad Regional Rosario, Departamento de Ingeniería Química, Grupo de Investigación Aplicada a la Ingeniería Química (GIAIQ)*.

### **Redes Neuronales en Tomografía Computarizada (TC)**

Las redes neuronales tienen como objetivo principal desarrollar una forma de aprendizaje automático que reconozcan patrones y predigan comportamientos mediante la recolección uniformada de datos específicos. Existen diferentes tipos de redes neuronales, cada una de ellas con ventajas diferentes pero que llevan al mismo objetivo; análisis más rápidos de grandes conjuntos de datos e información médica, mejoras en los protocolos de diagnóstico y pronóstico de enfermedades, aumentando la velocidad y reduciendo los errores médicos, diseño de terapias personalizadas más eficientes y mejoras en el bienestar humano Sarmiento (2020).

### ***Multilayer Perceptron (MLP)***

Sarmiento (2020) indica que:


Es una red neuronal artificial (ANN por sus siglas en inglés) compuesta por múltiples capas de neuronas ubicadas entre la entrada y la salida, conocidas como capas ocultas. La adición de estas capas permite incrementar el potencial de la red para solucionar problemas de clasificación y regresión con conjuntos de datos complejos (no lineales y discontinuos). El algoritmo de entrenamiento más extendido para esta red se conoce como backpropagation (BP), que consta de dos etapas:

La red es estimulada con una entrada, esta se propaga a través de la ANN desde la primera capa hasta la última, produciendo una salida.

La diferencia entre la salida deseada y salida obtenida es usada para ajustar los parámetros de la red empezando desde la última capa, avanzando hacia atrás, hasta la primera capa.

### **Figura 18**

*Multilayer perceptron (MLP)*



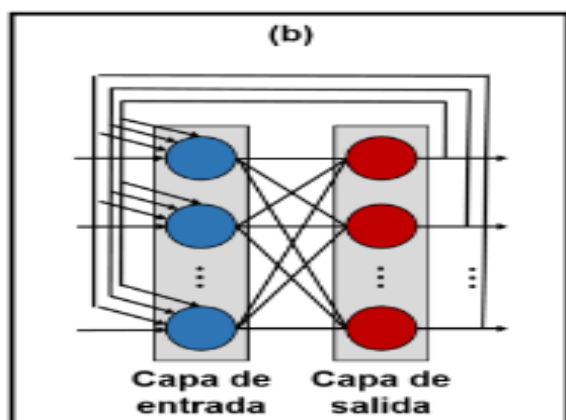
*Nota.* Imagen tomada de Sarmiento, J. (2020). *Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica.* Revista UIS Ingenierías, 19(4), 1–18.

## Red Neuronal de Hopfield

ANN introducida por J. Hopfield la cual funciona como una memoria asociativa, donde cada neurona está conectada a las demás. En el transcurso del entrenamiento, se le dan los ejemplos de entrada para que los almacene. Una vez entrenada, tiene la capacidad de recordar y reconocer estos patrones incluso si hay ruido (Sarmiento, 2020).

### Figura 19

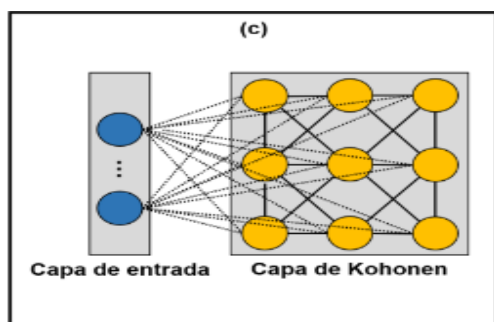
*Red neuronal de Hopfield*



*Nota.* Imagen tomada de Sarmiento, J. (2020). *Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica.* Revista UIS Ingenierías, 19(4), 1–18.

### *Self-organizing Maps (SOMs)*

Los mapas autoorganizados son un tipo de red introducido por Kohonen que funciona agrupando datos, tomándolos de entrada y los organiza según su similitud, se colocan una al lado de la otra cuando las neuronas tienen patrones similares (Sarmiento, 2020).

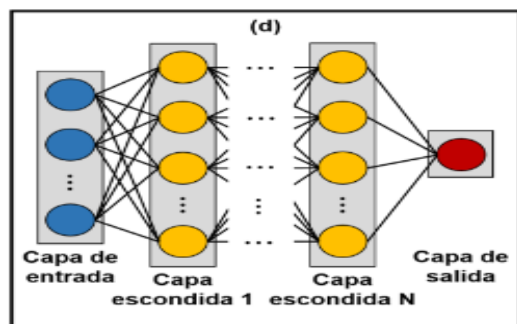
**Figura 20***Self-organizing map (SOM)*

*Nota.* Imagen tomada de Sarmiento, J. (2020). *Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica.* Revista UIS Ingenierías, 19(4), 1–18.

**Deep Learning (DL)**

Como indica Sarmiento, (2020):

El DL toma los fundamentos teóricos de las ANNs clásicas, pero emplea una gran cantidad de neuronas y capas ocultas, junto con nuevos modelos y paradigmas de entrenamiento ofreciendo una capacidad mucho mayor para aprender a adaptarse y extraer características de datos de entrada de alta complejidad. Las ANNs usadas en el DL son conocidas como redes neuronales profundas, en inglés deep neural networks (DNNs).

**Figura 21***Red neuronal profunda (DNN)*

*Nota.* Imagen tomada de Sarmiento, J. (2020). *Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica.* Revista UIS Ingenierías, 19(4), 1–18.

### ***Deep Multilayer Perceptron (DMLP)***


La red neuronal profunda multicapa es similar a la red MLP, no obstante, tiene más neuronas y capas ocultas, haciéndola de gran utilidad para problemas con datos complejos, Su desarrollo se debe a mejoras en métodos de entrenamiento y en la tecnología de computadoras (hardware y software) (Sarmiento, 2020).

### ***Deep Auto-encoder (DAE)***

Las redes DAE son un tipo especial de DMLP. Tienen dos características principales: el número de neuronas en la entrada y salida es el mismo, y las capas ocultas tienen menos neuronas. Esto las hace útiles para extraer y reducir características, y para preparar parámetros para redes más complejas (Sarmiento, 2020).

### **Figura 22**

#### *Deep auto-encoder (DAE)*



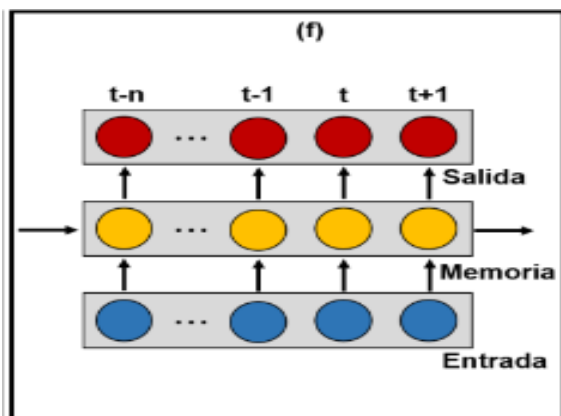
*Nota.* Imagen tomada de Sarmiento, J. (2020). *Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica.* Revista UIS Ingenierías, 19(4), 1–18.

### ***Recurrent Neural Network (RNN)***

Sarmiento (2020) señala que las redes neuronales recurrentes poseen una arquitectura donde las conexiones entre neuronas forman un gráfico dirigido a lo largo de una secuencia temporal, lo que les permite ser útiles para analizar datos en series de tiempo, exhibir un comportamiento dinámico, tener una memoria interna y mantener información sobre lo que sucedió en pasos de tiempos anteriores. Dentro de este tipo de arquitectura se encuentran las unidades de memoria a largo plazo (long-short term memory units, LSTM), que son especialmente diseñadas para aplicaciones donde se pueden presentar retrasos muy largos y desconocidos entre eventos importantes en la serie de tiempo.

#### **Figura 23**

*Red neuronal recurrente (RNN)*



Nota. Imagen tomada de Sarmiento, J. (2020). *Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica*. Revista UIS Ingenierías, 19(4), 1–18.

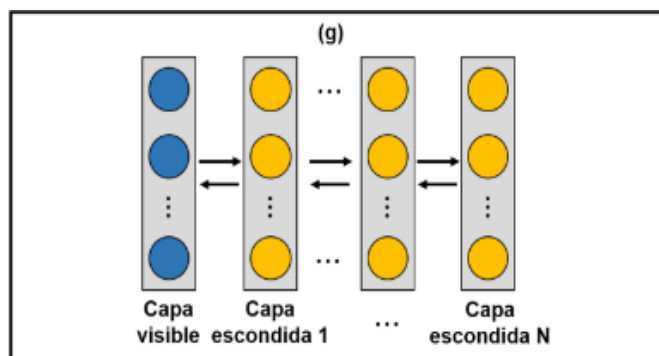
### ***Restricted Boltzmann Machine (RBM)***

La máquina restringida de Boltzmann es una red neuronal que aprende patrones probables de los datos, tiene una capa de neuronas visibles y otra oculta, conectándose entre sí, pero no dentro de cada capa, en general se usa para modelar relaciones probables y preparar parámetros

para redes más complejas. Las redes de creencias profundas (DBNs) son similares, pero cada capa oculta también actúa como capa visible para la siguiente (Sarmiento, 2020).

## Figura 24

### *Máquina restringida de Boltzmann (RBM)*



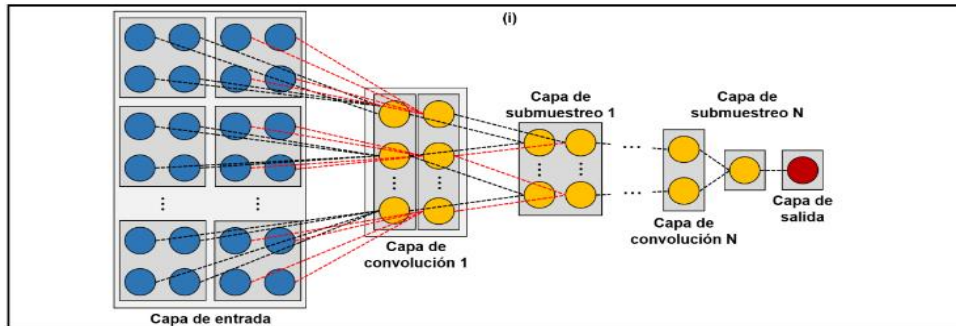
*Nota.* Imagen tomada de Sarmiento, J. (2020). *Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica.* Revista UIS Ingenierías, 19(4), 1–18.

### *Convolutional Neural Network (CNN)*

Sarmiento (2020) indica que las redes neuronales convolucionales (CNNs) se inspiran en cómo funciona la corteza cerebral durante la visualización, ya que cada neurona se conecta a una pequeña parte de la información siguiente, lo que les permite combinar patrones simples para crear patrones más complejos, usan una técnica llamada convolución para simplificar operaciones complicadas. Durante este proceso, los datos pasan por diferentes filtros que se desplazan a través de la información, y estos filtros usan los mismos parámetros en toda la red, reduciendo la cantidad de parámetros necesarios. Su uso principal es en tareas de visión artificial, como clasificar y segmentar imágenes.

**Figura 25**

*Red neuronal convolucional (CNN)*



*Nota.* Imagen tomada de Sarmiento, J. (2020). *Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica.* Revista UIS Ingenierías, 19(4), 1–18.

## **Metodología**

Este estudio tiene un enfoque cualitativo basado en una revisión sistemática de la literatura científica, acerca del uso de redes neuronales para la detección y corrección de artefactos en imágenes diagnósticas de tomografía computarizada (TC).

### **Enfoque Cualitativo**

Para Sánchez (2005), la investigación cualitativa es la conjunción de ciertas técnicas de recolección, modelos analíticos normalmente inductivos y teorías que privilegian el significado de los actores, siendo el investigador una parte integral del proceso de acopio, por ende, es parte del instrumento de recolección.

En cuyo caso se realiza una búsqueda de múltiples investigaciones acerca del uso de redes neuronales para la detección y reducción de artefactos en imágenes de Tomografía Computarizada, con el fin de analizar e identificar teorías, patrones, beneficios y desventajas que presenta la investigación.

### **Enfoque Descriptivo**

Se emplea para definir algunas características específicas de la investigación, en cuyo caso se utiliza con el propósito de detallar las particularidades necesarias para el funcionamiento de las redes neuronales en la detección de los artefactos en imágenes de tomografía computarizada.

### **Obtención de Datos**

Para este estudio se realizó una búsqueda exhaustiva en bases de datos académicas como Scielo, Elsevier, Google Scholar, Redalyc, repositorios, revistas, entre otras, utilizando palabras clave como redes neuronales en tomografía computarizada, redes convolucionales, aprendizaje

profundo, artefactos en tomografía computarizada, inteligencia artificial en TC, calidad de la imagen en TC.

### **Criterios de Inclusión**

Se considerarán artículos publicados en los últimos seis años que presenten avances metodológicos y aplicaciones clínicas de inteligencia artificial en imagenología médica. Además, se definirán normas para incluir o excluir estudios que traten sobre la detección y reducción de artefactos utilizando inteligencia artificial como el uso de redes neuronales convolucionales y otras redes usadas para el procesamiento de imágenes diagnósticas.

### **Limitaciones del Estudio**

Algunas limitaciones identificadas durante la investigación corresponden a Artículos en inglés sin posibilidad de traducción, variedad de documentos, artículos aplicados solo en Europa y otras regiones, artículos antiguos y desactualizados, artículos con errores en enlaces y/o privados que no permite la visualiza completa de estos, gran cantidad de artículos enfocados en resonancia magnética (RM).

### **Análisis de Datos**

Se evaluará de forma crítica los descubrimientos mencionados, reconociendo patrones, beneficios y desventajas de los métodos analizados. Por último, se unirán los hallazgos con el propósito de proporcionar una visión completa del estado presente del conocimiento en este campo y sus repercusiones en la mejora de la calidad del diagnóstico en tomografía computarizada.

**Parámetros Legales**

Aunque el presente trabajo se enfoca en la revisión bibliográfica de artículos de investigación y literarios, se garantiza la veracidad científica y transparencia en la citación de las fuentes usadas dando cumplimiento a las normas APA 7<sup>a</sup> edición.

## Resultados

En la presente investigación literaria basada en la “Implementación de redes neuronales para detectar y corregir artefactos en imágenes de tomografía computarizada: retos y oportunidades” se evidenciaron las principales causas por las que las imágenes diagnósticas no son idóneas para lectura médica debido a los artefactos, los cuales son ocasionados en el momento del estudio.

En la tabla 2 se relacionan algunas causas principales para conseguir una imagen diagnóstica con artefactos o artificios en TC, cabe destacar que cualquiera de los ítems relacionados puede ocurrir en distintos estudios y el principal objetivo que se busca es evitarlos a través del diálogo con el paciente, mantenimiento constante del equipo y el uso de redes neuronales como método complementario al detectar y corregir dichos artefactos que interfieren en una imagen de calidad diagnóstica.

### Tabla 2

#### *Tipos de artefactos en TC*

Artefactos en TC
Movimientos del paciente
Presencia de cuerpos extraños/material médico
Errores en las medidas de atenuación de los rayos X
Endurecimiento del haz de rayos X cuando estos traspasan al paciente
Efecto de volumen parcial
Ruido ( <i>quantum mottle</i> )
Mal funcionamiento de los detectores como consecuencia de errores de calibración o balanceo, efectos geométricos
Errores de espiral o “de remolino”
Factores ambientales

*Nota.* Sartori et al., 2015. *Revista Argentina De Radiología. Artefactos y artificios frecuentes en TC y RM* (p. 198).

Mediante la revisión bibliográfica se analizaron distintos artículos relacionados a redes neuronales para comprender el funcionamiento de ellas y su comportamiento. Según Flórez et al., (2008). “Las RNAs tratan de emular el comportamiento del cerebro humano, caracterizado por el aprendizaje a través de la experiencia y la extracción de conocimiento genérico a partir de un conjunto de datos” (p. 11). En este sentido se relaciona la tabla 3.

**Tabla 3**

*Comparación del cerebro humano vs computador convencional*

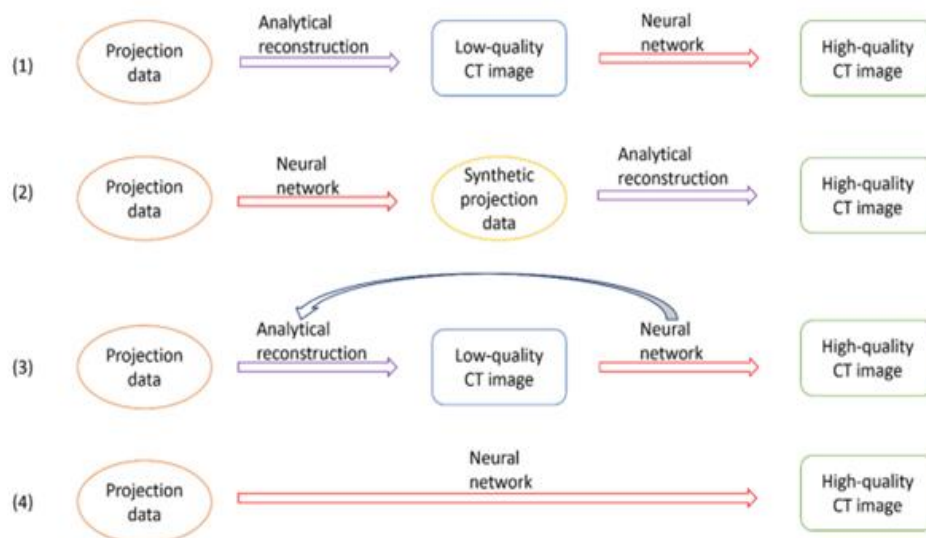
Características	Cerebro Humano	Computador
Velocidad de proceso	Entre $10^{-3}$ y $10^{-2}$ seg.	Entre $10^{-8}$ y $10^{-9}$ seg.
Estilo de procesamiento	Paralelo	Secuencial (en serie)
Numero de procesadores	Entre $10^{11}$ y $10^{14}$	Pocos
Conexiones	10.000 por procesador	Pocas
Almacenamiento del conocimiento	Distribuido	En direcciones fijas (posiciones precisas)
Tolerancia a fallos	Amplia	Poca o nula
Tipo de control del proceso	Autoorganizado (democrático)	Centralizado (dictatorial)
Consumo de energía para ejecutar una operación/sg	$10^{-16}$ Julios	$10^{-6}$ Julios

*Nota.* Flórez et al., 2008. *Redes neuronales artificiales Fundamentos teóricos y aplicaciones prácticas* (p. 12). *Nebiblo*.

Durante la investigación se ha analizado la importancia de las redes neuronales en el ámbito diagnóstico, siendo esta una evolución para el diagnóstico certero, el cual se relaciona en la siguiente figura como evidencia de un resultado positivo utilizando redes neuronales.

## Figura 26

*Proceso de los métodos de DL en diversos dominios*



*Nota.* Diversos caminos de métodos basados en aprendizaje profundo aplicados para la reconstrucción de imágenes en diferentes dominios. Imagen tomada de *The use of deep learning methods in low-dose computed tomography image reconstruction: A systematic review* (p. 5548), por Zhang et al., 2022, *Complex & Intelligent Systems*.

Para Zhang et al., (2022) “los métodos de aprendizaje automático (AA) pueden procesar una gran cantidad de datos y extraer patrones complejos. Sin embargo, un tamaño de muestra pequeña puede ser un problema grave en la reconstrucción de TC de baja dosis” (p. 5555).

En este contexto, el rendimiento de las redes y los resultados pueden ser poco confiables o incluso inferiores a los métodos analíticos convencionales. Para superar estas barreras, se proponen enfoques como el “aprendizaje no supervisado, por transferencia, de una sola muestra, autosupervisado y gradual” (p. 5555). Sin embargo, el aprendizaje supervisado enfrenta complicaciones relevantes a causa de la escasez de datos etiquetados y la posible presencia de errores en los datos de dosis normal, lo que afecta la calidad de la imagen reconstruida y limita su aplicación clínica debido a los riesgos asociados a la radiación en procedimientos diagnósticos en pacientes.


Por ende, la calidad y cantidad del conjunto de datos de entrenamiento son determinantes para el desempeño de los métodos de reconstrucción basados en aprendizaje profundo (Deep Learning). Puesto que los datos clínicos suelen provenir de bases públicas y la simulación de dosis bajas se realiza añadiendo ruido artificial, es necesario desarrollar métodos no supervisados confiables que mejoren la reconstrucción de TC de baja dosis. Ahora bien, la generalización de estos métodos es crucial para su aplicabilidad práctica en diferentes conjuntos de datos, niveles de ruido, escáneres, proveedores y regiones anatómicas, manteniendo la fiabilidad en todos los casos. Aprovechar la similitud entre datos de distintas modalidades también puede reducir la radiación necesaria para los pacientes.

Así mismo, mejorar la interpretabilidad de las redes neuronales profundas en el análisis de imágenes de tomografía computarizada es un reto constante, y resulta clave para el uso efectivo de estas técnicas.

Por otra parte, Carrizales et al., (2024), en su artículo de investigación “Detección de artefactos en imágenes 4DCT mediante aprendizaje profundo” sugieren que el modelo de aprendizaje profundo AD2 permite identificar de forma eficaz varios tipos de artefactos en imágenes 4DCT y facilita su potencial eliminación, apoyando los métodos de corrección que dependen de AD2 para localizar dichos artefactos. A pesar de los desafíos y oportunidades constantes para su perfeccionamiento, “la integración de AD2 en la práctica clínica es muy prometedora” (p. 1105), especialmente para avanzar en la radioterapia (RT) y mejorar la calidad de las imágenes médicas, posicionándose como una solución clave para el persistente problema de los artefactos causados por el movimiento respiratorio.

## Figura 27

### Modelo AD2 Vs observador humano



*Nota.* Fila 1 muestra la predicción del modelo (con un umbral de 0,94) comparada con la segmentación del observador humano. Fila 2 muestra el resultado bruto del modelo, un mapa de probabilidad, que ilustra la certeza del modelo respecto a la ubicación de los artefactos. Imagen tomada de *Detección de artefactos en imágenes 4DCT mediante aprendizaje profundo* (p. 1102), por Carrizales et al., 2024, *Med Phys*.

De acuerdo con Chan et al., (2020), el aprendizaje profundo promete revolucionar el diagnóstico asistido por computadora (CAD) y el análisis de imágenes médicas, superando las limitaciones de los enfoques tradicionales de aprendizaje automático. “El éxito reciente de la tecnología de aprendizaje profundo impulsa nuevos esfuerzos para desarrollar herramientas CAD o IA para muchas aplicaciones en el cuidado de la salud” (p. 15). Aunque los resultados recientes son prometedores, aún existen desafíos importantes para su integración clínica, como la necesidad de grandes bases de datos, validaciones rigurosas, estándares de calidad y capacitación adecuada de los usuarios.

Del mismo modo, una herramienta de apoyo a la toma de decisiones solo será aceptada si no implica tiempo ni costos adicionales sin beneficios clínicos claros; no obstante, si se desarrolla, valida e implementa correctamente, el análisis eficiente de datos mediante

herramientas CAD o IA puede complementar la inteligencia médica, mejorando la precisión, optimizando el flujo de trabajo y, en consecuencia, la calidad de la atención al paciente.

Por otro lado, Bustos (2022), establece que “Los métodos algebraicos en la reconstrucción de imágenes médicas ofrecen una reducción significativa del ruido, artefactos y artificios, mejorando notablemente la calidad de imagen”. Una ventaja clave es que no requieren todas las proyecciones convencionales de un estudio rutinario, lo que implica una considerable reducción en la dosis de radiación al paciente (p. 39). Además, El uso de algoritmos paralelos y filtros avanzados optimiza la adquisición y el procesamiento de señales, aumentando la eficiencia del proceso.

Así mismo, los métodos estadísticos dejan limpiar imágenes de manera eficiente, a pesar de que su ejecución requiere adaptaciones complejas en el hardware actual. Para acelerar el procesamiento, se propone el uso de unidades de procesamiento gráfico (GPU), lo que facilitaría el desarrollo de nuevos algoritmos con la capacidad de minimizar los artefactos que dificultan la interpretación clínica. Con respecto a la corrección de movimientos voluntarios e involuntarios, se logra modificando las proyecciones y desplazando matrices para realizar correcciones geométricas; al aplicar procesos iterativos sobre estas matrices, es posible reconstruir imágenes libres de artefactos de movimiento y con menor ruido.

Por último, los ruidos y artefactos en las imágenes no solo provienen de fuentes externas sino también de factores internos como variaciones en el voltaje, desalineación de detectores o falta de calibración. La combinación de algoritmos analíticos y matemáticos ha demostrado mejorar la calidad de imagen al corregir estos problemas. En conjunto, estos avances en métodos algebraicos y estadísticos, junto con el uso de hardware especializado, representan un progreso importante para obtener imágenes médicas de mayor precisión y menor exposición radiológica.

A su vez, Garrido (2019) señala que cuando las imágenes provienen de diferentes instrumentos, ubicaciones o técnicos y presentan variaciones significativas, como diferencias de color, brillo o rotación, la clasificación empeora.

Esto provoca que la clasificación dé peores resultados de los esperados, ya que tendríamos un espacio muy difuso y poco concreto que no se adecúa a ningún conjunto de imágenes en concreto, por lo que no se pueden extraer un número suficiente de características comunes entre todas las imágenes para poder hacer más precisas las predicciones de los modelos de aprendizaje automático (p. 52).

Para Zétera (2023) “El uso de aprendizaje profundo aplicado a sinogramas para disminuir el ruido presente, junto con time reversar como método de reconstrucción mejora sustancialmente la calidad de las imágenes finales en comparación de LBP” (p. 53). Por lo tanto, la comparación entre la mejora en las métricas y el tiempo de reconstrucción indica que la red neuronal convolucional de super-resolución (SRCNN) es una opción eficaz para reducir el ruido en los sinogramas.

Ko et al., (2021) presentan un método aplicable a múltiples sistemas y capaz que manejan movimientos rígidos y no rígidos en tomografía computarizada (TC). Este enfoque precursor aborda múltiples escenarios de movimiento dentro del mismo marco ofreciendo un rendimiento en tiempo real, lo que resulta beneficioso para aplicaciones en radioterapia.

El sistema se basa en un potente modelo de redes neuronales convolucionales profundas (CNN), reconocidas por su capacidad para modelar problemas no lineales complejos, siendo ideales para esta tarea, en específico redes residuales con un mecanismo de autoatención, el cual es introducido por primera vez en esta tarea. La elección responde a la complejidad no lineal de los artefactos de movimiento, estos surgen a causa de la mezcla y registro de múltiples tejidos en

un solo píxel durante el movimiento del paciente, generando imágenes borrosas no estacionarias. “El método propuesto se puede aplicar a cualquier sistema de TC, ya que solo requiere una imagen de TC 2D como entrada”.

Para Farhan et al., (2024) los enfoques de aprendizaje automático (ML), aprendizaje profundo (DL), híbridos y de optimización proporcionan el mejor rendimiento en todas las etapas del sistema de Análisis de Imágenes Médicas (MIA), estos enfoques deben aprovechar técnicas avanzadas de IA y metodologías híbridas que integren a la perfección todos los aspectos importantes, mitigando el nivel actual de complejidad (p. 120).

Hernández et al., (2021) en su artículo de investigación establece que el método iterativo OSEM destacó en la reconstrucción de imágenes con corrección de endurecimiento de haz, ofreciendo mejor eliminación de artefactos, mayor contraste y mejor relación señal-ruido que el algoritmo FBP, a pesar de su costo computacional elevado; del mismo modo, el procesamiento mediante histograma mejoró significativamente el preprocesamiento de los datos. “Al seleccionar adecuadamente los algoritmos, se pueden desarrollar sistemas para el tratamiento de imágenes con artefactos de endurecimiento de haz con mayor eficacia, los cuales permitirán mejores diagnósticos y detección temprana de enfermedades”.

Yim et al., (2021) proponen una red de aprendizaje profundo con capas convolucionales y deconvolucionales para reconstruir imágenes de TC a partir de pocas vistas, transformando directamente las proyecciones en imágenes sin requerir conocimientos especializados en reconstrucción. Comparada con los métodos clásicos FBP y SART, “la red mejora la precisión cuantitativa y reduce el ruido”, demostrando ser más eficaz para la reconstrucción en escenarios de datos limitados.

Zeng (2023) en su artículo “Algoritmo iterativo de dominio sinograma guiado por redes neuronales para la reducción de artefactos” propone utilizar una red neuronal para definir automáticamente una función objetivo que cuantifica la gravedad de los artefactos en imágenes, superando la dificultad de modelar matemáticamente estos errores. La red se entrena con imágenes etiquetadas binariamente (con y sin artefactos) y, tras eliminar ciertas capas, genera una función continua que evalúa la calidad de la imagen en cada iteración del algoritmo de reconstrucción. Aunque este enfoque requiere menos datos complejos que otros métodos de aprendizaje automático, la función objetivo no es convexa debido a activaciones no lineales, por lo que el algoritmo solo garantiza converger a mínimos locales. Los resultados muestran una reducción significativa pero no completa de los artefactos, por ende, limita la capacidad del modelo para representar todos los tipos de artefactos y la complejidad del espacio de optimización.

## Conclusiones

Las redes neuronales han demostrado ser una herramienta fundamental en el procesamiento y análisis de imágenes de tomografía computarizada, permitiendo avances significativos en la precisión diagnóstica y automatización de procesos médicos. La literatura revisada destaca la capacidad de las redes neuronales para aprender representaciones profundas que facilitan la identificación de características relevantes en imágenes de TC, lo que contribuye a mejorar la eficiencia y efectividad del diagnóstico, sin embargo, su implementación enfrenta diversos retos y oportunidades.

**Tabla 4**

*Retos y oportunidades*

Retos	Oportunidades
Escasez y calidad variable en datos	Métodos no supervisados y aprendizaje por transferencia
Complejidad computacional y necesidad de hardware especializado	Uso de GPU y algoritmos híbridos
Generalización y robustez limitada	Redes avanzadas de auto atención y super resolución
Interpretabilidad y aceptabilidad clínica	Herramientas CAD/IA validadas y eficientes
Artefactos y ruidos persistentes	Detección y corrección automática de artefactos

*Nota.* Autoría propia

Uno de los principales desafíos identificados es la limitada disponibilidad de datos clínicos de calidad, especialmente aquellos etiquetados de manera precisa. Los modelos de aprendizaje profundo (DL) dependen de estos datos para funcionar de forma correcta, sin embargo, llevado a la práctica, la obtención de grandes volúmenes de información confiable no siempre es tan fácil, lo cual afecta la capacidad de los modelos para trabajar correctamente

comprometiendo la calidad de las imágenes reconstruidas, en especial cuando el objetivo es reducir la dosis de radiación para proteger al paciente.

Frente a esta realidad, se abren oportunidades muy interesantes con técnicas como el aprendizaje no supervisado, por transferencia o autosupervisado. Estas estrategias permiten trabajar con conjuntos de datos más pequeños (o incluso sin etiquetas), lo que es valioso en la práctica clínica, puesto que los recursos y la disponibilidad de datos pueden ser limitados. Aun así, se requiere validaciones rigurosas y evaluación constante de su rendimiento evitando posibles fallas.

Otro aspecto que se debe tener en cuenta es la capacidad de los modelos para adaptarse a las diversas variaciones que existen entre distintos equipos de TC, fabricantes y regiones anatómicas. La realidad es que no todas las imágenes médicas son iguales, y eso puede afectar mucho el funcionamiento de los modelos si no han sido diseñados para lidiar con ello, es aquí donde entra en juego la necesidad de que los modelos sean verdaderamente robustos y versátiles, con la capacidad de mantener un buen desempeño sin importar el entorno de entrenamiento y desarrollo.

Además, se destaca la importancia de mejorar la interpretabilidad de estos sistemas. Para que estas herramientas sean adoptadas, es necesario comprender su funcionamiento lógico y por qué la imagen es evaluada de cierta manera. Por ello la confianza en la tecnología es clave cuando se trata de decisiones clínicas.

Por otro lado, se identificaron avances relevantes en el tratamiento de artefactos en imágenes médicas, especialmente los causados por el movimiento respiratorio en estudios como la 4DCT, en donde modelos como "AD2" y enfoques basados en sinogramas con redes neuronales convolucionales (CNN) han demostrado ser eficaces en este sentido, lo que

representa una oportunidad para mejorar la calidad de las imágenes y, por ende, el diagnóstico y tratamiento de los pacientes, especialmente en campos como la radioterapia.

No obstante, no se puede dejar de lado el valor que aún tienen los métodos analíticos y estadísticos clásicos. Estos enfoques siguen siendo útiles, especialmente cuando se busca reducir la dosis de radiación o corregir artefactos complejos. Asimismo, la combinación de estas técnicas con nuevas herramientas de inteligencia artificial, junto al uso de hardware especializado como las unidades de procesamiento gráfico (GPU), podría ser un camino muy prometedor hacia sistemas más eficientes y potentes.

En resumen, los avances en reconstrucción de imágenes médicas de TC mediante inteligencia artificial ofrecen enormes beneficios potenciales, como lo son una mejor precisión diagnóstica, menor exposición a la radiación y trabajo clínico más ágil. Ahora bien, también traen consigo nuevos retos que deben abordarse con responsabilidad. Este trabajo permite concluir que el verdadero potencial de estas tecnologías se alcanzará cuando se logre un equilibrio entre innovación tecnológica, rigurosidad científica y necesidades humanas. De manera que se pueda que estas herramientas complementan la labor médica y mejoran, de forma real y sostenible la calidad de vida de los pacientes.

### Referencias Bibliográficas

- Armiñana, A., Montón, C., Puig, A., Infante, T., Fontenla, C., Torres, I., & Martí, L. (2023). Spectral CT and Hounsfield Units: basis for correct interpretation. *Anales de la Real Academia Nacional de Medicina*, 140(02), 101–113. <https://doi.org/10.32440/ar.2023.140.02.rev01>
- Bosch, E. (2004). Sir Godfrey Newbold Hounsfield Y La Tomografía Computada, Su Contribución A La Medicina Moderna. *Revista chilena de radiología*, 10(4), 183-185.  
[https://www.scielo.cl/scielo.php?pid=s0717-93082004000400007&script=sci\\_arttext](https://www.scielo.cl/scielo.php?pid=s0717-93082004000400007&script=sci_arttext)
- Bustos, C. (2022). *Simulación de artificios en imágenes de tomografía computarizada y clasificación automática usando algoritmos de machine learning*. (tesis de grado). ECCI.  
<https://repositorio.ecci.edu.co/bitstream/handle/001/2908/Trabajo%20de%20grado.pdf?sequence=1&isAllowed=y>
- Calzado, A. & Geleijns, J. (2010) Tomografía computarizada. Evolución, principios técnicos y aplicaciones. *Revista de Física Médica*. <https://revistadefisicamedica.es/index.php/rfm/article/view/115/115>
- Carrizales, J, Mattison, J., Fairbourn, D., Shao, W., Gerard, S., Bayouth, J., Christensen, G., & Reinhardt, J. (2024). 4DCT image artifact detection using deep learning. *Medical Physics*, 52(2), 1096–1107. <https://doi.org/10.1002/mp.17513>
- Chan, H., Samala, R., Hadjiiski, L., & Zhou, C. (2020). Deep Learning in Medical Image Analysis. *Advances in experimental medicine and biology*, 1213, 3–21. [https://doi.org/10.1007/978-3-030-33128-3\\_1](https://doi.org/10.1007/978-3-030-33128-3_1)
- Duarte, O. (2014). *Inteligencia Artificial [Presentación de diapositivas]*. SlideServe.  
<https://www.slideserve.com/taffy/inteligencia-artificial>
- Farhan, O., Basavara, J., Naji, M., Ghaleb, O., Ahmed, A., Ahmed, H., & Esmail, H. (2024) Efficient artificial intelligence approaches for medical image processing in healthcare:

- comprehensive review, taxonomy, and analysis. *Journal of Computer Science and Technology*, 39(1). <https://link.springer.com/article/10.1007/s10462-024-10814-2#Sec81>
- Flórez, R. & Fernández, J. (2008). Las redes neuronales artificiales Fundamentos teóricos y aplicaciones prácticas. *Netbido, S.L.*  
<https://books.google.es/books?hl=es&lr=&id=X0uLwi1Ap4QC&oi=fnd&pg=PA11&dq=redes+neuronales&ots=gPLCenmrXm&sig=h-9yUcbB-7BYltgBlS Y4cPcSPig#v=onepage&q&f=true>
- Garrido, R. (2019). Estructuración jerárquica y semántica de la información extraída de imágenes de tomografía computarizada y resonancia magnética. (Proyecto Fin de Carrera / Trabajo Fin de Grado). *E.T.S. de Ingenieros Informáticos (UPM), Madrid, España.*  
[https://oa.upm.es/56310/1/TFG\\_ROBERTO\\_GARRIDO\\_GARCIA.pdf](https://oa.upm.es/56310/1/TFG_ROBERTO_GARRIDO_GARCIA.pdf)
- Hernández, Y., & Fernández, Y. (2021). Algoritmos para el procesamiento de imágenes con artefactos de endurecimiento de haz en tomografía computarizada. *Revista Cubana de Ciencias Informáticas*, 15(2), 96-117.  
<https://www.redalyc.org/journal/3783/378367420006/html/>
- Ko, Y., Moon, S., Baek, J., & Shim, H. (2021). Reducción de artefactos de movimiento rígido y no rígido en tomografías computarizadas de rayos X mediante el uso de un módulo de atención. *Análisis de imágenes médicas*, 67, 101883.  
<https://www.sciencedirect.com/science/article/abs/pii/S1361841520302474>
- Matich, D. (2001). Redes Neuronales: Conceptos Básicos y Aplicaciones. *Universidad Tecnológica Nacional. Cátedra: Informática Aplicada a la Ingeniería de Procesos – Orientación I.*  
[https://www.firro.utn.edu.ar/repositorio/catedras/quimica/5\\_anio/orientadora1/monogriais/matich-redesneuronales.pdf](https://www.firro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monogriais/matich-redesneuronales.pdf)

- Paudyal, R., Shah, A., Akin, o., Do, R., Konar, A., Hatzoglou, V., Mahmood, U., Lee, N., Wong, R., Banerjee, S., Shin, J., Veeraraghavan, H., Shukla-Dave, A. (2023). Inteligencia artificial en imágenes por TC y RM para aplicaciones oncológicas. *PMC*. [https://pmc-ncbi-nlm-nih-gov.translate.google/articles/PMC10177423/?\\_x\\_tr\\_sl=en&\\_x\\_tr\\_tl=es&\\_x\\_tr\\_hl=es&\\_x\\_tr\\_pto=tc](https://pmc-ncbi-nlm-nih-gov.translate.google/articles/PMC10177423/?_x_tr_sl=en&_x_tr_tl=es&_x_tr_hl=es&_x_tr_pto=tc)
- Pérez L. (2012). La escala de Hounsfield. Modulo técnica radiológica 1 Guanacaste. *Blogspot*. <http://modulotecguana.blogspot.com.co/2012/08/la-escala-de-hounsfield.html>
- Radiologia Latam. (2024). La evolución de los tomógrafos: historia, funcionamiento y avances. *RadiologiaLatam*. <https://radiologialatam.com/la-evolucion-de-los-tomografos-historia-funcionamiento-y-avances/>
- Sánchez, M. (2005). La metodología en la investigación cualitativa. *Mundo siglo XXL*. <https://repositorio.flacsoandes.edu.ec/bitstream/10469/7413/1/REXTN-MS01-08-Sanchez.pdf>
- Sarmiento, J. (2020). Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica. *Revista UIS ingenierías*, 19(4), 1–18. <https://doi.org/10.18273/revuin.v19n4-2020001>
- Sartori, P., Rozowykniat, M., Siviero, L., Barba, G., Peña, A., Mayol, N., Acosta, D., Castro, J., & Ortiz, A. (2015). Artefactos y artificios frecuentes en tomografía computada y resonancia magnética. *Revista Argentina de Radiología*, 79(4), 192–204. <https://www.sciencedirect.com/science/article/pii/S0048761915000794?via%3Dihub#bib0110>
- Yim, D., Lee, S., Nam, K., Lee, D., Kim, K., & Kim, J. (2021). Reconstrucción de imágenes basada en aprendizaje profundo para tomografía computarizada de pocas vistas. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 1011, 165594. <https://www.sciencedirect.com/science/article/abs/pii/S0168900221005799>

Zeng, G. (2023). Neural network guided sinogram-domain iterative algorithm for artifact reduction. *Medical Physics*, 50(9), 5410–5420.

<https://pmc.ncbi.nlm.nih.gov/articles/PMC10529507/>

Zétera, J. (2023). *Optimización de la Reconstrucción de Imagen para Tomografía Fotoacústica Utilizando Aprendizaje Profundo* (Tesis de Maestría). Instituto Nacional de Astrofísica, Óptica y Electrónica. <https://inaoe.repositorioinstitucional.mx/jspui/handle/1009/2486>

Zhang, M., Gu, S., & Shi, Y. (2022). El uso de métodos de aprendizaje profundo en la reconstrucción de imágenes de tomografía computarizada de baja dosis: una revisión sistemática. *Complex & Intelligent Systems*, 8, 5545- 5561.

<https://link.springer.com/article/10.1007/s40747-022-00724-7>