

**Exploración del potencial de la inteligencia artificial en la calidad del diagnóstico de
imágenes médicas**

Jhon Alexia Cala Pérez

Leidy Viviana Esteban Bonza

Luz Amparo Cepeda Rojas

Reymond Ferney Hernández López

Yurley Katherine Arciniegas Reyes

Universidad Nacional Abierta y a Distancia - UNAD

Escuela de Ciencias de la Salud (ECISA)

Tecnología en Radiología e Imágenes Diagnosticas

2022

Dedicatoria

Este trabajo es dedicado a todos los profesionales en el área de radiología ávidos de conocimiento, curiosos, que les gusta estar en la vanguardia de su disciplina. Esperamos con ansias que el contenido de este trabajo les resulte provechoso.

Agradecimientos

Agradecimientos especiales a todos los que de una u otra forma contribuyeron a la realización de este trabajo y a la formación de los profesionales que lo escribieron: profesores, compañeros de estudio, personal de la universidad, familiares, hermanos, hijos, investigadores de toda parte del mundo que con sus trabajos habilitaron la construcción de este.

Resumen

Este estudio explora el estado actual de las aplicaciones de inteligencia artificial en imágenes médicas y proporciona una evaluación de cómo los errores interpretativos se reducen a la par que mejora la calidad de la práctica médica. A lo largo de la investigación, se analiza diferentes aspectos como el error diagnósticos y el procesamiento de imágenes digitales. Además, se proporciona una breve base teórica que explica cómo funciona el aprendizaje profundo y cómo está siendo útil en imágenes médicas. El artículo concluye con una reflexión sobre el tema.

Palabras Clave: imagen diagnóstica, error interpretativo, detección asistida por computadora, inteligencia artificial, aprendizaje profundo.

Abstract

This study explores the current state of artificial intelligence applications in medical imaging and provides an assessment of how misinterpretation is reduced while improving the quality of medical practice. Throughout the investigation, different aspects such as diagnostic error and digital image processing are analyzed. In addition, a brief theoretical background is provided explaining how deep learning works and how it is being useful in medical imaging. The article concludes with a reflection on the subject.

Key Words: diagnostic imaging, interpretive error, computer-aided detection, artificial intelligence, deep learning.

Tabla de Contenido

Introducción	8
Planteamiento del Problema	10
Justificación	12
Objetivos	14
Objetivo general	14
Objetivos específicos	14
Marco Teórico.....	15
Error Interpretativo Radiológico.....	15
Causas del Error Interpretativo	16
Proceso de Interpretación.....	17
Errores de Omisión	18
Atención y Percepción	20
Estrategias para Reducir el Error Interpretativo en el Diagnóstico	21
Metodología	22
Desarrollo del Proyecto.....	23
Inteligencia Artificial	25
Inteligencia Artificial Aplicada al Diagnóstico de Imágenes Médicas.....	29
Conclusiones.....	35
Referencias.....	37

Lista de Figuras

Figura 1. Diagrama de los factores de errores interpretativos de diagnóstico.....	17
Figura 2. Diferentes tipos de errores de omisión.....	19
Figura 3. Esquema de una red neural artificial.....	28
Figura 4. Radiografía de tórax que muestra opacidades bilaterales.....	32

Introducción

Las imágenes médicas son un área en medicina que se utiliza para diagnosticar una enfermedad para su tratamiento temprano. El análisis y la interpretación de imágenes médicas son tareas cognitivas fundamentales de un radiólogo, dichas tareas son influenciadas por las limitaciones humanas y presentan incidencia recurrente de errores. Históricamente, la automatización efectiva de estas tareas ha sido difícil, sin embargo, los investigadores de ciencias de la computación utilizan una técnica llamada aprendizaje profundo que han demostrado mejoras de rendimiento revolucionarias en una variedad de tareas complejas.

Esta técnica se utilizan para mejorar la precisión mediante la extracción de patrones significativos para la enfermedad específica en imágenes médicas. El procesamiento de imágenes digitales ofrece una mejora significativa en el procedimiento de toma de decisiones basado en algunas predicciones, es decir, da una mejor extracción de características y precisión.

Los avances en la tecnología de inteligencia artificial han creado entusiasmo y temor entre los profesionales de la radiología. Con el advenimiento de conceptos como el aprendizaje automático y las redes neuronales artificiales que prometen una interpretación de imágenes precisa y rápida, se cree que es el siguiente paso en la evolución de la radiología. La capacidad de reducir el tiempo de interpretación de imágenes y aumentar la detección a niveles más allá de lo que es posible para el ojo humano podría crear un impacto revolucionario y cada vez más necesario cuando el error humano sigue presente en el diagnóstico.

La inteligencia artificial en radiología se ha centrado en mejorar tres principios generales atribuidos a las limitaciones humanas: eficiencia, objetividad y estandarización (Sarmiento & García, 2021). Al examinar los usos y limitaciones actuales en radiología, se puede reconocer la importancia de esta tecnología de rápido crecimiento y hacia dónde puede dirigirse en la mejora

de la calidad del diagnóstico por imágenes médicas. Este artículo explora los conceptos de inteligencia artificial en el campo médico y el papel que está teniendo la su aplicación en la reducción de errores y en la mejora de la calidad del diagnóstico con imágenes médicas.

Planteamiento del Problema

Las imágenes juegan un papel fundamental en el proceso de diagnóstico de muchos pacientes, testigo de ello es el estimado de mil millones de exámenes radiológicos que son realizados en todo el mundo (Bruno et al., 2015), donde la mayoría son interpretados por profesionales en el área.

Adrián Brady, radiólogo del Hospital Universitario Mercy, explica que a veces es posible ser definitivo en los diagnósticos radiológicos, pero en la mayoría de los casos, la interpretación radiológica está fuertemente influenciada por las circunstancias clínicas del paciente, antecedentes relevantes e imágenes previas, entre otros grupo de factores, incluidos los sesgos de los que se puede no ser conscientes (2017).

Los errores y las discrepancias en la práctica de la radiología son incómodamente comunes, con estimaciones de tasas de error de diagnóstico promedio que oscilan entre el 3% y el 5%, hay aproximadamente 40 millones de errores de diagnóstico que involucran imágenes anualmente en todo el mundo (Bruno et al., 2015). El potencial para mejorar el rendimiento del diagnóstico y reducir el daño al paciente al identificar y aprender de estos errores es sustancial y requerido.

Los principales factores de error responsables encontrados en la literatura son factores técnicos como: el protocolo de imagen utilizado, uso del contraste adecuado, malas condiciones de ergonomía; y humanos como: excesiva carga laboral, inexperiencia profesional, información clínica inadecuada entre el médico remitente y el radiólogo, y fatiga tanto visual como mental (García M., 2003) (Gálvez M & Montoya M, 2017). Adicional, hay oportunidades en los estudios radiológicos para incorporar sistemas de reconocimiento que indiquen las anomalías más significativas y sirvan de herramienta para la interpretación de imágenes.

La digitalización de las imágenes trajo consigo muchas ventajas, las imágenes electrónicas se pueden ver casi inmediatamente después de la adquisición en una pantalla, en lugar de esperar a que se procese una película, y pueden almacenarse y construir un historial médico donde diferentes proveedores de salud tendrán acceso a la información.

La capacidad de manipular una imagen digital presenta también una enorme ventaja diagnóstica sobre la película. El software de visualización permite al radiólogo utilizar el zoom para obtener un primer plano de áreas específicas, la sustracción digital para mejorar la definición de la imagen, el apilamiento de imágenes para la visualización en serie, la mejora del contraste y otros beneficios (Rossi & Miguel, 2004). Aun así, es mucho el potencia no explotado, los centros radiológicos almacenan enormes cantidades de información susceptible de ser utilizada para realizar diagnósticos más precisos y minimizar los errores que son indeseablemente comunes en este campo.

Justificación

Los errores en radiología diagnóstica son comunes, como se mencionó en la sección de problema, y ocurren por una variedad de razones vinculadas a factores humanos, técnicos y fallas del sistema. Con tasas de error entre el 3 al 5 % por año, es un desafío existente que los centros de imágenes médicas deben enfrentar. Más que juzgar al personal médico, es importante desplegar herramientas y políticas de soporte para ayudarles a reducir este indicador.

Entre un 60 a 80% de los errores de interpretación en radiología son causados por errores de percepción (Santos, 2022). Estos deslices son influenciados por la atención y la percepción y son complejos de identificar y controlar por lo que no se pueden prevenir por completo. Hay muchos otros factores de error como Iluminación deficiente, altos niveles de trabajo, rápidos tiempos de lectura, que influyen directamente en qué tan bien opera cualquier radiólogo (García M., 2003). Identificar los factores contribuyentes es una de las claves para desarrollar intervenciones que los mitigue.

Existen varias estrategias para apoyar al personal médico y minimizar el error diagnóstico, estas abarcan desde sistemas de informes estructurados hasta revisión por pares (Santos, 2022). Un área en la que la tecnología ha desempeñado un papel importante en la reducción de los errores de radiología es la introducción de la inteligencia artificial.

Las imágenes médicas aportan información diagnóstica clave al proceso de decisión terapéutica basado en la evidencia. La transformación de imágenes radiológicas en un flujo digital de datos permite la integración con otras fuentes de datos de diagnóstico de patología y medicina de laboratorio como base para los sistemas de orientación de decisiones clínicas (Rossi & Miguel, 2004). La utilidad de la digitalización en la práctica médica no es discutible.

Una preocupación emergente en radiología hoy en día es el crecimiento exponencial de

los datos frente a la escasez de personal médico; el volumen, la velocidad, y la variedad de estos datos no tienen precedentes, la afluencia de imágenes se han vuelto tan prolífica que presiona a los radiólogos a escanear más y más imágenes por segundo como nunca antes. La ciencia de datos y las tecnologías digitales tienen el potencial de procesar montañas de datos aislados en información útil.

Si bien algunos promocionan la inteligencia artificial como el reemplazo del radiólogo, la realidad es mucho más interesante. Con la inteligencia artificial, los radiólogos reciben una herramienta que les permite ajustar el proceso, reducir los errores de diagnóstico, mejorar la toma de decisiones y minimizar la administración.

Todas las imágenes pueden ser evaluadas constantemente por un sistema de inteligencia artificial, uno que está configurado para detectar todas las anomalías y garantizar que sean vistas por el profesional correspondiente. La inteligencia artificial tiene el potencial de convertirse en una herramienta precisa que, cuando lo maneja el médico adecuado, ahorra tiempo, vidas y errores de diagnóstico.

Una computadora no puede reemplazar la percepción, la intuición y las habilidades correlativas de un médico, pero esta tecnología tiene el potencial de aumentar aún más la precisión diagnóstica de la interpretación de radiografías, lo que lleva a una mejor toma de decisiones clínicas. La presente investigación aborda el diagnóstico basado en datos de imágenes médicas usando algoritmos de inteligencia artificial.

Objetivos

Objetivo general

Explorar el rol que está teniendo la inteligencia artificial en la reducción de errores interpretativos y de percepción, y cómo mejora de la calidad del diagnóstico con imágenes médicas

Objetivos específicos

Conocer los conceptos básicos de inteligencia artificial para poder entender sus aplicaciones en el campo médico.

Consultar el estado del arte actual del uso de inteligencia artificial en el procesado de imágenes médicas digitales.

Construir un consenso con base a la bibliografía analizada el rol actual de la inteligencia artificial en la calidad del diagnóstico de imágenes médicas.

Marco Teórico

Más de una década ha pasado desde que el Instituto de Medicina estimó que entre 44.000 y 98.000 personas mueren en los hospitales de los Estado Unidos cada año como resultado de errores prevenibles (Kohn, 2009). En análisis más reciente, un trabajo de un grupo de investigadores muy citados estimó en más de 251.000 el número de pacientes muertos por año debido a errores de diagnóstico médico, lo que sugiere que el error médico es la tercera causa más común de muerte en los Estados Unidos después del cáncer y las enfermedades cardíacas (Makary & Daniel, 2016). Las interpretaciones diagnósticas de los radiólogos tienen un tremendo impacto en las tasas de error de diagnóstico que resultan de un diagnóstico tardío o erróneo (Santos, 2022).

Error Interpretativo Radiológico

El error interpretativo ha sido innato a las imágenes médicas desde sus comienzos. Ya en el 1949, Garland encontró una tasa de error del 33,3% en la lectura de películas basadas en la opinión de consenso grupal y una variación intralector del 8%, que es cuando un lector no está de acuerdo consigo mismo al releer una imagen (Garland, 1949). Esta tasa de error se ha mantenido prácticamente sin cambios. Representando la práctica clínica típica, en una combinación de estudios anormales y normales la tasa de error es de aproximadamente el 4 % (Sabih et al., 2010). Debido a que anualmente se realizan mil millones de exámenes radiográficos en todo el mundo, una tasa de error del 4% se traduce en aproximadamente 40 millones de errores de interpretación por año (Bruno et al., 2015).

Afortunadamente, la mayoría de los errores son o menores o significativos pero se detectan y corrigen con suficientemente rápido para evitar daños graves al paciente (Martínez et al., 2018). De la misma manera, muchos errores de interpretación resultan perjudiciales para los

pacientes y pueden ser una experiencia humillante y frustrante para los radiólogos (Barajas-Ochoa & Ponce-Horta, 2017).

A pesar de los avances en la tecnología de imágenes, no hay evidencia de mejora en las capacidades perceptivas del ojo y el cerebro humanos (Kim & Mansfield, 2014). Dada esta limitación humana, muchas de las soluciones desarrolladas para disminuir el error interpretativo se basan en la tecnología (Machacado-Rojas & Aparicio-Pico, 2021).

Causas del Error Interpretativo

Los errores de percepción representan del 60 al 80 % de los errores de interpretación, con variaciones en técnica y en escenarios (Itri et al., 2018). Debido a que el primer paso en la interpretación de imágenes es la detección, un error en la percepción puede terminar prematuramente el proceso de diagnóstico y conducir a diagnósticos omitidos. Para que un error de interpretación se considere un error de percepción, el hallazgo debe ser lo suficientemente detectable por parte de los radiólogos que lo interpretan o en el consenso de sus colegas (Bruno et al., 2015). Por lo tanto, no todos los hallazgos sutiles e irrelevantes encontrados posterior al análisis se consideran errores de percepción.

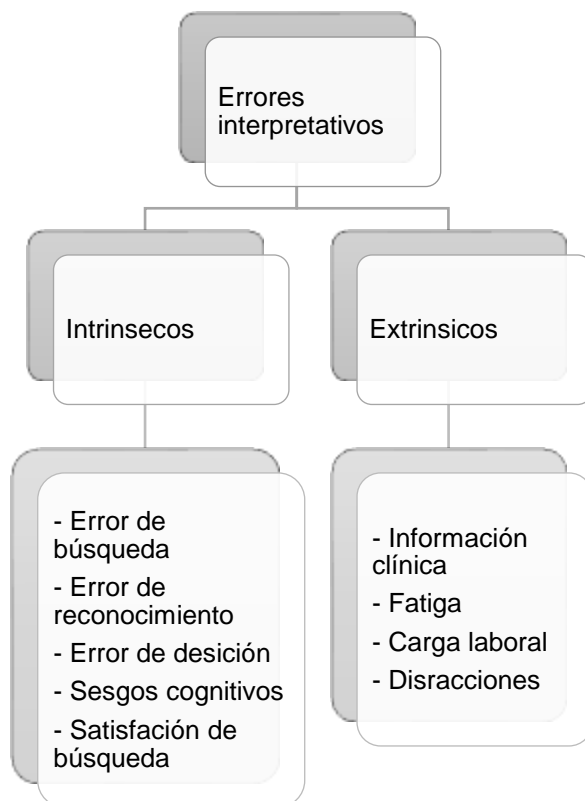
Las características intrínsecas de las lesiones o hallazgos influyen en su detectabilidad y dependen de las propiedades físicas de la lesión y sus estructuras circundantes. El contraste es una propiedad que compone la lesión y su entorno, cuanto mayor sea la diferencia entre los dos, mejor será la visibilidad (Gálvez, 2016). Nódulos de tamaño pequeño, baja atenuación de la lesión y márgenes mal definidos son características poco visibles en la radiografía de tórax por ejemplo (Ventura Alfaro, 2018).

Además de las características intrínsecas de la lesión, existen varios factores tanto intrínsecos como extrínsecos que pueden contribuir a la probabilidad de un error de

interpretación, como se resumen en la Figura 1.

Figura 1

Diagrama de los factores de errores interpretativos de diagnóstico



Fuente: elaboración propia.

Proceso de Interpretación

Se requiere conocer cómo los humanos analizan y procesan las imágenes para comprender el error de percepción e interpretación. Al escanear el entorno, los ojos realizan movimientos aleatorios, llamados movimientos sacádicos, intercalados con períodos de fijación (Santos, 2022). La visión depende de la información obtenida durante las pausas de fijación entre movimientos sacádicos, porque no se obtiene información visual útil mientras los ojos están en movimiento (Santos, 2022).

Se postula que al analizar un estudio radiológico, existe una identificación rápida de

anomalías utilizando la visión periférica con un escrutinio posterior utilizando la visión central. Los radiólogos comparan las impresiones con la información contenida en su memoria a largo plazo de forma que discernen qué información hay en una imagen (Santos, 2022).

Luego se produce una segunda exploración que permite el reconocimiento de objetos. Las características se examinan de cerca para determinar si un hallazgo es sospechoso. Las decisiones se toman una vez que las características de la imagen coinciden lo suficiente con el esquema cognitivo del espectador (Facal de Castro et al., 2019). Esta vía, que dura de segundos a minutos, tiene una capacidad limitada y es el cuello de botella de la atención.

Errores de Omisión

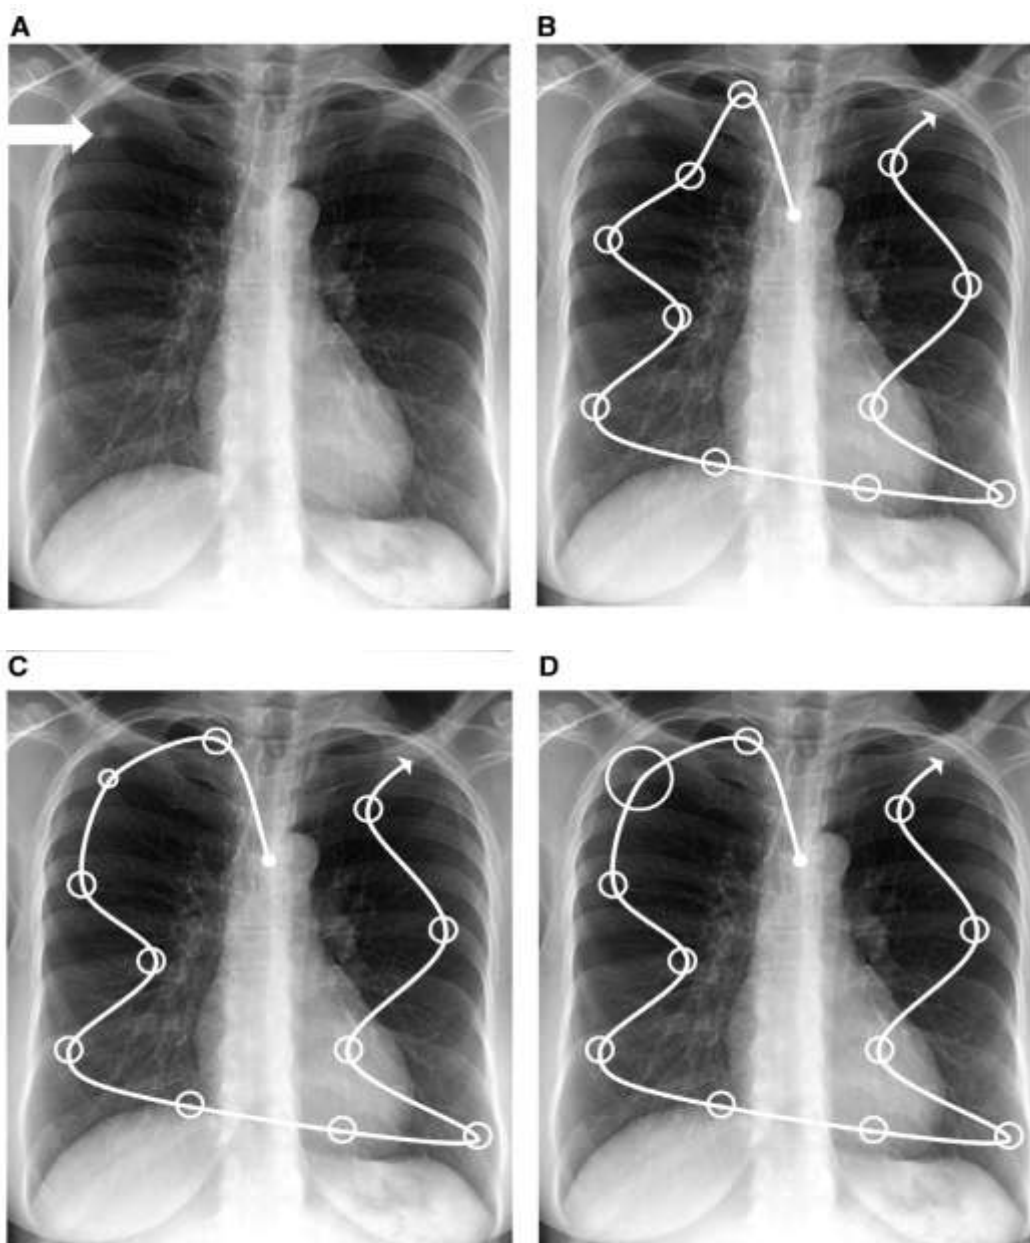
La tecnología de seguimiento ocular se ha utilizado para clasificar los errores de omisión o falsos negativos en tres categorías sobre la base de los tiempos de fijación en las lesiones perdidas: búsqueda, reconocimiento y toma de decisiones (Onder et al., 2021), se resumen en la Figura 2.

- Error de búsqueda: este tipo de error ocurre cuando el observador nunca se fija en la lesión lo que impide el procesamiento (véase Figura 2B).
- Error de reconocimiento: un error de reconocimiento es una falla del mecanismo básico de reconocimiento de objetos; el espectador se fija en el objetivo durante un tiempo más corto que el umbral de tiempo de permanencia que se considera suficiente para reconocer las características de la lesión. El umbral para la detección de lesiones depende de la modalidad de imagen y oscila entre 500 y 1000 ms (Degnan et al., 2019). Tanto los errores de búsqueda como los de reconocimiento se consideran errores de percepción (véase Figura 2C).
- Error de toma de decisión: Los errores en la toma de decisiones ocurren cuando

un radiólogo se fija en la lesión durante un período prolongado de más de 1s, pero no reconoce las características o las descarta (Figura 2D).

Figura 2

Diferentes tipos de errores de omisión



Fuente: tomado de *Perceptual and interpretive error in diagnostic radiology—causes and potential solutions*, Academic Radiology, por A. J. Degnan et al., 2019. Reproducido con

permiso de autor.

Nota. La línea blanca indica la trayectoria de la mirada del observador, los círculos indican puntos de fijación y el diámetro de los círculos está relacionado con la duración de la fijación. A) La flecha blanca grande indica un nódulo en el lóbulo superior derecho. B) Error de búsqueda, el nódulo no está fijado. C) Error de reconocimiento, el nódulo se fija, pero solo brevemente. D) Error de decisión, el nódulo se fija durante unos segundos, el observador toma una decisión incorrecta de no identificar la anormalidad como un nódulo.

Atención y Percepción

El aprendizaje, la memoria, la atención y la expectativa dan forma a este proceso de percepción. La falta de atención es una fuente de error en radiología. Debido a que los humanos no pueden procesar todo en el campo visual, la atención se dirige a los objetos que tienen características intrínsecas prominentes, esto se conoce como procesamiento de abajo hacia arriba. El color, el movimiento, la orientación y el tamaño se encuentran entre los atributos que guían la búsqueda visual y se denominan "preatención", lo que significa que se perciben rápidamente sin ningún esfuerzo consciente (Facal de Castro et al., 2019).

Las diferencias en el procesamiento atencional explican las variaciones en los patrones de búsqueda entre expertos y novatos. Los radiólogos expertos saben dónde buscar nódulos, lo que limita la inspección de muchas áreas irrelevantes, incluyendo en errores de omisión lo que se conoce como ceguera por falta de atención (Degnan et al., 2019). Se considera como una limitación inherente del ser humano, por lo tanto, la ceguera por falta de atención no se puede prevenir por completo.

Un caso práctico de ceguera por falta de atención se encuentra en (Potchen, 2006), donde el 60% de los radiólogos no notaron una clavícula faltante en una radiografía de tórax cuando se

les niega la historia relevante. Cuando se les indicó que la radiografía de tórax formaba parte de un estudio metastásico, el 83% de los observadores encontraron la anomalía.

Estrategias para Reducir el Error Interpretativo en el Diagnóstico

Muchas de las soluciones propuestas para reducir el error interpretativo están basadas en la tecnología porque las computadoras no están sujetas a las limitaciones humanas (Machacado-Rojas & Aparicio-Pico, 2021). El diagnóstico asistido por computadora es una de las soluciones disponibles actualmente.

La detección asistida por computadora (CAD) se refiere al software de reconocimiento de patrones que marca características sospechosas en una imagen médica en un intento de disminuir las lecturas de falsos negativos y evitar omisiones.

La inteligencia artificial se refiere a la capacidad de las computadoras para tomar decisiones que normalmente requerirían inteligencia humana. Los algoritmos de inteligencia artificial se han utilizado durante varios años en el campo de CAD, pero aún no han sido adoptados en gran escala (Álvarez Vega et al., 2020). Las nuevas técnicas de inteligencia artificial como algoritmos de aprendizaje profundo tienen el potencial de mejorar la interpretación y la percepción, esta nueva generación funciona encontrando patrones directamente de las imágenes médicas tras cientos de escaneos, simulando la forma en que aprenden los humanos. En este trabajo se explora el potencial de la inteligencia artificial en el diagnóstico de las imágenes médicas.

Metodología

Debido a que el objetivo de este proyecto es explorar el rol de la inteligencia artificial, se adopta un enfoque cualitativo descriptivo, con el que se buscará comprender un fenómeno a través de la lectura intencionada y analítica de bibliografía especializada. Este método de investigación fue implementado en proyectos con objetivos similares, lo cual fue evidenciado en una búsqueda bibliográfica previa (Corbacho et al., 2021) (Álvarez Vega et al., 2020).

La recopilación de información se realiza de fuentes formales disponibles electrónicamente para asegurar su fiabilidad, pertinencia y calidad; las bases de datos usadas son principalmente Scielo y Google Académico. El periodo de observación es comprendido desde el 2017 en adelante (5 años a la actualidad) para garantizar la actualidad en la revisión. Los términos de búsqueda empleados son inteligencia artificial y imágenes médicas o imágenes diagnósticas; como estrategia para recopilar información de calidad se revisa las referencias de los artículos en búsqueda de fuentes recientes y significativas en el tema de esta investigación, varias de ellas en inglés.

Una vez realizada la búsqueda, la información se filtra con una primera lectura del título y resumen, dejando así la más relevante que es analizada a detalles y cuya síntesis se plasma en el desarrollo de la solución.

Desarrollo del Proyecto

Durante la última década, la inteligencia artificial ha logrado un éxito revolucionario en el reconocimiento de patrones, como la videovigilancia, la conducción autónoma, el procesamiento del lenguaje natural y, por supuesto, el análisis de imágenes médicas. La inteligencia artificial aplicada a la medicina busca emular la cognición humana en el análisis, interpretación y comprensión de los datos (Algarabel & Manuel, 2019).

Con la creciente madurez de la digitalización y el almacenamiento de bajo costo, grandes cantidades de datos médicos, como imágenes estructurales humanas, registros de salud electrónicos, información genética, están ampliamente disponibles. Estos datos podrían ser un recurso habilitador para derivar soluciones médicas de inteligencia artificial para mejorar la prestación de atención. En particular, las imágenes médicas de alto volumen y bien estructuradas, como: rayos X, tomografía computarizada, imágenes por resonancia magnética, y ultrasonido, sirven de base para el desarrollo de algoritmos análisis de imágenes asistidos por inteligencia artificial para el diagnóstico de enfermedades en radiología, por ejemplo (A N et al., 2021).

Hoy en día, los hospitales están buscando soluciones digitales que aumenten el ahorro de costos, mejoren la precisión del diagnóstico y mejoren la satisfacción del paciente. La inteligencia artificial, especialmente el aprendizaje profundo, ha logrado un progreso notable en la interpretación, el diagnóstico asistido y el tratamiento basados en imágenes médicas (Rouhiainen, 2020). En esta revisión se revisa el avance de las soluciones de inteligencia artificial derivadas de imágenes médicas con énfasis en la calidad del diagnóstico y disminución del error interpretativo.

Los lectores de este proyecto probablemente estén familiarizados con los términos de imágenes médicas, sin embargo, puede que muchos no sepan qué significa la inteligencia

artificial y cómo se puede utilizar en tareas de análisis e interpretación de imágenes médicas. Por lo tanto, la ejecución de la solución comienza con una revisión de los términos claves que aparecen con frecuencia en los artículos radiológicos de inteligencia artificial para ayudar la comprensión de las aplicaciones (Algarabel & Manuel, 2019) (Machacado-Rojas & Aparicio-Pico, 2021):

- Segmentación: es el proceso de dividir la imagen en partes, el objetivo de este paso es determinar dónde comienza y termina algo, por ejemplo: en una imagen diagnóstico con un tumor, la segmentación puede definir donde termina y comienza el tumor, sin que esto necesariamente indique que es un tumor.
- Etiquetado de datos: es el proceso de identificar datos sin procesar y agregar una o más etiquetas de valor y así proporcionar información para que un modelo aprender de ellos. En el contexto de imagen médica, esta tarea podría ser definir si hay cáncer presente o el tipo de cáncer que representa la lesión.
- Clasificación: se refiere al proceso que etiquetado y categorización cualquier tipo de datos para que puedan entenderse y analizarse mejor, por ejemplo, asignar una etiqueta a un área de la imagen diagnóstica como zonas con tejido maligno.
- Modelo: es el patrón aprendido por un sistema de aprendizaje automático. Una vez aprendido, el modelo se puede asignar a una imagen desconocido para predecir a qué clase pertenece ese ejemplo.
- Algoritmo: la serie de pasos llevada a cabo para crear el modelo que se usará para predecir o detectar características a partir de las características de los ejemplos de entrenamiento.
- Entrenamiento: es la fase durante la cual el sistema de algoritmo es alimentado con un

conjunto de datos de entrada que se utiliza para enseñarle al modelo. Al conjunto de ejemplos utilizados durante el entrenamiento se les conoce como conjunto de validación.

- Pruebas: es el conjunto de ejemplos que se utilizan para verificar y mejorar la eficacia de un modelo, con esto se evita que el modelo aprenda características únicas del conjunto de entrenamiento.
- Lenguaje de programación: consiste en un vocabulario y un conjunto de reglas gramaticales para decirle a una computadora que realice tareas específicas. Los lenguajes de programación populares incluyen Python, Java, C, C++, C#, JavaScript, R y MATLAB (Malberti et al., 2021).

La popularidad de Python está aumentando en el campo del análisis de datos debido a su facilidad de aprendizaje y la disponibilidad de muchas bibliotecas y marcos útiles, hay varios marcos comúnmente usados como TensorFlow, Keras, PyTorch, y CNTK (Malberti et al., 2021).

Inteligencia Artificial

La inteligencia artificial puede definirse como el campo de las ciencias que investiga métodos para hacer máquinas inteligentes y que así puedan realizar tareas que usualmente necesitan la inteligencia humana (Rouhiainen, 2020). El aprendizaje automático, o aprendizaje de máquina, es una amplia rama de la inteligencia artificial que se ocupa de aprender de datos sin ser programado explícitamente para ello, en términos técnicos es un algoritmo que permite aprender patrones y estructuras estadísticas intrínsecas en los datos (Rouhiainen, 2020).

Se puede aplicar un algoritmo de aprendizaje automático a un conjunto de datos, como por ejemplo imágenes de tumores, y a alguna etiqueta sobre estos datos, como tumores benignos o malignos, y entonces el algoritmo puede aprender de los datos y entrenarse para aplicar lo ha aprendido en hacer una predicción, continuando con el ejemplos, podría detectar si una imagen

diferente muestra tejido tumoral benigno o maligno. El algoritmo puede optimizar sus parámetros con más y más datos de manera que su rendimiento mejora, lo que se traduce en que diagnostica correctamente más casos de prueba (Machacado-Rojas & Aparicio-Pico, 2021).

Los enfoques de aprendizaje automático más comunes en el análisis de imágenes médicas se puede dividir en aprendizaje supervisado, aprendizaje no supervisado y aprendizaje semi supervisado, dependiendo de cuánta información de anotación se proporcione al sistema de aprendizaje informático (Malberti et al., 2021) (Puentes et al., 2021):

- Aprendizaje supervisado: se alimenta el algoritmo de aprendizaje con entradas clínicas y sus salidas deseadas, esto requiere un agente humano para clasificar de forma manual los ejemplos de entrenamiento. El objetivo enseñarle a que asigne entradas a salidas correctas. Las técnicas típicas en el aprendizaje supervisado para el reconocimiento de imágenes incluyen la regresión y la clasificación.
- Aprendizaje no supervisado: no se proporcionan etiquetas a los datos, por lo tanto, el algoritmo de la computadora necesita encontrar el patrón por sí mismo. Dos métodos principales en el aprendizaje no supervisado para el análisis de imágenes son el análisis de componentes principales y la agrupación.
- Aprendizaje semi supervisado: hay datos etiquetados y no etiquetados disponibles para los algoritmos de aprendizaje, esto permite mejorar la exactitud del aprendizaje.

Por lo general, solo se puede adquirir una pequeña cantidad de datos etiquetados debido al alto costo en tiempo y dinero, mientras que una gran cantidad de datos no etiquetados son fácilmente disponibles. Esto es especialmente atractivo en escenarios análisis de imágenes donde las etiquetas suelen ser costosas de anotar, mientras que hay disponible una gran cantidad de datos estructurados en imágenes sin etiquetar o débilmente etiquetadas (Puentes et al., 2021).

Los métodos tradicionales de aprendizaje automático requieren la extracción de características a partir de las entradas, un problema con este enfoque es que es posible que los rasgos característicos no se conozcan bien de antemano, o al menos no se entiendan completamente (Nam et al., 2019). Esto es particularmente aplicable en imágenes médicas.

El aprendizaje profundo es un subconjunto del aprendizaje automático que usa múltiples capas de algoritmos para extraer progresivamente patrones, ello le permite aprender características directamente de los datos sin necesidad de explicitarlas y utilizarlas para resolver problemas. Con la llegada de grandes conjuntos de datos y una mayor potencia informática, estos métodos pueden producir modelos con un rendimiento excepcional (Extremo, 2021).


Para ilustrar el funcionamiento del aprendizaje profundo se diseña el siguiente ejemplo: los tumores benignos y tumores malignos son usualmente fáciles de diferenciar debido a sus características específicas: los tumores benignos suelen ser pequeños y homogéneos, con bordes bien definidos, mientras que los tumores malignos suelen ser más grandes y heterogéneos, con bordes difusos que a menudo invaden el tejido circundante. En un enfoque de aprendizaje profundo, el algoritmo se entrena solamente con imágenes etiquetadas como benignas o malignas y él extrae las características distintivas de las imágenes durante el análisis y luego es capaz de predecir el resultado de una imagen diferente (Extremo, 2021).

Los algoritmos de aprendizaje profundo se componen de unidades llamadas redes neuronales artificiales (Chanampe et al., 2019). Una red neuronal artificial es un modelo informático simple que emula el modo en que el cerebro procesa la información: consiste de un número de unidades de procesamiento interconectadas que parecen modelos digitales de neuronas. Las unidades de procesamiento se organizan en capas y se conectan con ponderaciones (ver Figura 3).

La red neural recibe los datos en la capa de entrada, y los valores se propagan capa tras capa hasta sacar un resultado por la capa de salida. A través del análisis de datos individuales, la red va ajustando sus ponderaciones, lo que mejora sus predicciones hasta alcanzar un criterio de parada.

Figura 3

Esquema de una red neural artificial



Fuente: tomado de *Pronostico del rendimiento del IPC mediante el uso de redes neuronales*, por Cabrera Llanos & Ortiz Arango, 2012. Reproducido con permiso de autor.

Nota. Se observa el esquema de capas de una red neuronal: una capa de entrada, una o varias capas ocultas y una capa de salida.

La red neural recibe los datos en la capa de entrada, y los valores se propagan capa tras capa hasta sacar un resultado por la capa de salida. A través del análisis de datos individuales, la red va ajustando sus ponderaciones, lo que mejora sus predicciones hasta alcanzar un criterio de

parada.

Se hace importante incluir dos definiciones más (Chanampe et al., 2019):

- **Nodo:** parte de una red neuronal que involucra dos o más entradas y una función de activación. La función de activación generalmente suma las entradas y luego usa algún tipo de función y umbral para dar una salida.
- **Capa:** una colección de nodos que calcula las salidas de una o más entradas.

Las arquitecturas de redes neuronales más importantes que se utilizan en radiología son redes neuronales convolucionales, redes neuronales recurrentes y redes antagónicas generativas. Se diferencian entre ellas en complejidad y aplicación particular apropiada, por ejemplo: las redes neurales convolucionales asemeja las neuronas que se pueden encontrar en la corteza visual, son muy útiles para tareas de visión artificial y el tipo de red más usado en el procesamiento de imágenes médicas (Chanampe et al., 2019).

La expansión del aprendizaje profundo han sido impulsados por cuatro principales avances:

1. La disponibilidad de grandes cantidades de datos de imágenes digitales de alta calidad para capacitación.
2. la capacidad de los algoritmos para aprender información relevante directamente de las imágenes sin necesidad de extensiva ayuda.
3. Alta capacidad de procesamiento gráficos y de bajo costo.
4. Bibliotecas de desarrollo de código abierto y redes de ejemplo de trabajo puestas a disposición gratuitamente por empresas e investigadores.

Inteligencia Artificial Aplicada al Diagnóstico de Imágenes Médicas

El análisis y la interpretación de imágenes médicas son tareas cognitivas fundamentales

de un radiólogo, que lleva consigo sesgos y errores de interpretación. En la bibliografía se encontró que la detección y el diagnóstico asistidos por algoritmos de aprendizaje automático pueden ayudar a los médicos a interpretar los hallazgos de imágenes médicas al indicarles las zonas con posibles hallazgos, también pueden reducir los tiempos de lectura y la incidencia de error humano. La tecnología de aprendizaje profundo aplicada a las imágenes médicas puede convertirse en la tecnología más disruptiva que la radiología haya visto desde la llegada de las imágenes digitales (Sarmiento & García, 2021).

Antes de adentrarse en las aplicaciones del aprendizaje profundo en radiología, es bueno entender cómo las computadoras representan imágenes (Toquero, 2021): una imagen digital es una colección de elementos llamados píxeles, ensamblados en un sistema de cuadrícula. Cada píxel representa un color y se puede localizar de forma única en una imagen mediante un par de coordenadas fila-columna. En imágenes médicas se trabajan predominantemente imágenes en escala de grises, en este caso, cada píxel tiene un valor entero de 0 a 255 que representa una cantidad de luz. El límite inferior indica la ausencia total de luz y corresponde al negro, mientras que el valor máximo representa la presencia total de luz y se asocia al blanco; cualquier valor que se encuentre entre estos valores representa un tono de gris. Las computadoras almacenan las imágenes digitales como matrices de valores numéricos que son convertidos en cantidad de luz para representar su contenido.

Un modelo de aprendizaje automático se alimenta de la señal de intensidad y de orientación espacial de un píxel, o de matrices pequeñas de píxeles, para extraer las características de la imagen de entrada (Toquero, 2021). Las capas ocultas son las responsables de este proceso, usualmente se utilizan muchas capas ocultas para poder extraer todas las características. El objetivo es obtener fenotipos distintivos, por ejemplo, en el caso de un tumor

canceroso: el tamaño, la forma, la textura, la cinética.

El método de aprendizaje profundo más utilizado son las redes neuronales convolucionales. Además, las imágenes de resonancia magnética son las más empleadas como datos de entrenamiento. Recomendaciones expertos médicos acusan que cada método de análisis de imágenes requiere personalizaciones específicas para la tarea y la modalidad de imagen (Pérez et al., 2022).

Una aplicación reportada en la literatura es la detección de anomalías o lesiones usando algoritmos de aprendizaje profundo (Pérez et al., 2022) (Raschio et al., 2021) (Corbacho et al., 2021), en radiografías de tórax y mamas principalmente. La salida de estos algoritmos es usualmente la imagen original con la localización del objeto y una etiqueta del hallazgo, como se puede evidenciar en la Figura 4.


La implementación de algoritmos de aprendizaje profundo representaron un fuerte despliegue frente a los tradicionales algoritmos de inteligencia artificial. La posibilidad de identificar y clasificar datos semi brutos esparció su interés y reanimó sus aplicaciones como coadyuvante en la interpretación y diagnóstico mediante imágenes médicas, y como estrategia para reducir el error humano en estas tareas.

Las aplicaciones del aprendizaje profundo en el cuidado de la salud cubren una amplia gama de problemas que van desde la detección del cáncer y el control de enfermedades hasta sugerencias de tratamientos personalizados. El procesamiento de imágenes y el aprendizaje automático juegan un papel vital en el diagnóstico y análisis de estas enfermedades, ayudando a los médicos a tomar decisiones de tratamiento rápidas de manera eficiente y precisa (Toquero, 2021). Hay varias fuentes de datos en la actualidad: imágenes radiológicas (rayos X, tomografías computarizadas y resonancias magnéticas), imágenes de patología y, recientemente, secuencias

genómicas (Pérez Careta et al., 2022).

Figura 4

Radiografía de tórax que muestra opacidades bilaterales



Fuente: tomado de Artificial Intelligence in diagnostic radiology: Where do we stand, challenges, and opportunities, *Journal of Computer Assisted Tomography*, por Moawad et al., 2022.

Nota. Se utiliza una red neuronal convolucional para detectar las lesiones en el cuadro delimitador y después clasificar estas lesiones con una probabilidad.

Una aplicación de lo anterior es encontrada en el diagnóstico de Alzheimer, para esta enfermedad, los escáneres cerebrales se utilizan de forma rutinaria para determinar el diagnóstico. Saraf y su equipo diagnosticaron la enfermedad de Alzheimer en adultos mayores mediante imágenes de resonancia magnética (Sarraf et al., 2016). El modelo aprendizaje

profundo empleado para la detección de cerebros sanos o cerebros afectados por la enfermedad de Alzheimer arrojó una precisión de 98,84 % para los datos de resonancia magnética.

Otra aplicación es encontrada en medicina pulmonar. Un nódulo pulmonar es un crecimiento anormal de tejido en este órgano y que puede volverse canceroso. El diagnóstico clínico de los nódulos pulmonares se basa principalmente en imágenes, incluidas la radiografía de tórax, la tomografía computarizada o por emisión de positrones y la resonancia magnética nuclear. Un proyecto de (Liu et al., 2019) aplican métodos actualizados de inteligencia artificial para detectar nódulos pulmonares, mejorando así la eficacia y precisión de las decisiones clínicas.

La detección automática de lesiones está aún en etapa de desarrollo y existen desafíos para competir con el desempeño de un profesional. Los enfoques actuales se enfocan en diseñar redes neuronales más complejas para mejorar su desempeño en la detección en tiempo real (Corbacho Abelaira et al., 2021). A futuro sería una herramienta que ayudará a los radiólogos con una segunda opinión, a no dejar pasar nada por alto y a reducir el tiempo de escaneo.

El aprendizaje profundo no solo ayuda a seleccionar y extraer características, sino también a construir otras nuevas; los nuevos enfoques van más allá de diagnosticar una enfermedad, buscando proporcionar modelos de predicción procesables para ayudar a los médicos a desarrollar planes de tratamiento efectivos.

El futuro del aprendizaje profundo en imágenes médicas no está tan cerca como el de otras aplicaciones de imágenes debido a las complejidades involucradas en este campo. La noción de aplicar algoritmos basados en el aprendizaje profundo a los datos de imágenes médicas es un área de investigación en crecimiento, sin embargo, existen varias barreras que frenan su avance. Estos desafíos incluyen la falta de disponibilidad de conjuntos de datos, problemas

legales y de privacidad, falta de estandarización de formatos de imágenes, expertos médicos dedicados (para etiquetar las imágenes médicas por ejemplo), algoritmos de aprendizaje automático más robustos (Gorospe-Sarasúa et al., 2022). Estas barreras están reduciendo el crecimiento del aprendizaje profundo en el sector de la salud.

Otro problema presente encontrado en la literatura fue la llamada caja negra. Los algoritmos de aprendizaje automático reciben inmensas cantidades de datos como entrada, identifican patrones y construyen modelos predictivos; sin embargo, es aún un reto entender cómo funciona el modelo (Gorospe-Sarasúa et al., 2022).

Conclusiones

En su mayoría, las interpretaciones de los datos médicos son analizadas por expertos en el área. En cuanto a la interpretación de imágenes por parte de un radiólogo, esta es bastante limitada debido a su subjetividad y la complejidad de las imágenes. Existen amplias variaciones entre los expertos, y las razones son diversas como fatiga por la carga de trabajo.

El aprendizaje profundo se perfila como un coequipero de los profesionales en radiología en el posprocesamiento de las imágenes. Sus usos son diversos y tienen en común la mejora de la calidad del servicio médico. El objetivo de utilizar algoritmos de inteligencia artificial es identificar las características asociadas a una condición para su posterior aplicación en el desarrollo de modelos predictivos para su uso en la evaluación de riesgos, detección, diagnóstico, pronóstico, respuesta terapéutica, riesgo de recurrencia, etc.

Existen desafíos para la implementación de estos algoritmos en el campo médico. Para que el aprendizaje profundo en radiología tenga éxito, se necesitan grandes conjuntos de datos debidamente procesados, redes profundas más complejas, nueva legislación en el tema y estandarización. Sin embargo, se espera que el aprendizaje automático tenga un impacto clínico sustancial con los exámenes de imágenes que se obtienen de forma rutinaria en la práctica clínica, brindando una oportunidad para mejorar el apoyo a la toma de decisiones en la interpretación.

Sin lugar a duda, la inteligencia artificial no son soluciones de reemplazo para los médicos, pero contribuirán a optimizar las tareas de rutina y, por lo tanto, tendrán un impacto positivo potencial en nuestra práctica. El papel de los profesionales es clave para el desarrollo e implementación de dichas soluciones. Actualmente, los radiólogos tienen una oportunidad histórica de participar en una revolución científica mediante la comprensión del aprendizaje

profundo, participando en la concepción y evaluación de nuevas herramientas, pero también contribuyendo a concebir un marco para la regulación de este nuevo tipo de actividad médica.

Referencias

- Algarabel, A., & Manuel, S. (2019, May). *Desarrollo de un sistema de análisis de imágenes médicas basado en técnicas de Deep Learning*. repositorio.uam.es. UAM.
<https://repositorio.uam.es/handle/10486/688901>
- Álvarez Vega, M., Quirós Mora, L. M., & Cortés Badilla, M. V. (2020). *Inteligencia artificial y aprendizaje automático en medicina*. *Revista Medica Sinergia*, 5(8).
<https://doi.org/10.31434/rms.v5i8.557>
- Barajas-Ochoa, A., & Ponce-Horta, A. M. (2017). *Reconocer los errores diagnósticos, UN Paso Necesario Para Abordarlos*. *Salud Pública De México*, 60(1, ene-feb), 109.
<https://doi.org/10.21149/8418>
- Bruno, M. A., Walker, E. A., & Abujudeh, H. H. (2015). *Understanding and confronting our mistakes: The epidemiology of error in radiology and strategies for error reduction*. *RadioGraphics*, 35(6), 1668–1676. <https://doi.org/10.1148/rg.2015150023>
- Cabrera Llanos, A. I., & Ortiz Arango, F. (2012). *Pronóstico del Rendimiento del IPC (índice de Precios Y cotizaciones) mediante el uso de redes neuronales diferenciales*. *Contaduría y Administración*, 57(2). <https://doi.org/10.22201/fca.24488410e.2012.185>
- Chanampe, H., Aciar, S., Vega, M., Sotomayor, J., & Carrascosa, G. (2019). *Modelo de redes neuronales convolucionales profundas para la clasificación de lesiones en ecografías mamarias*. UNLP. <http://sedici.unlp.edu.ar/handle/10915/77381>

- Corbacho Abelaira, M. D., Ruano-Ravina, A., & Fernández-Villar, A. (2021). *Inteligencia artificial en Radiología Torácica. ¿Un reto en tiempos de la covid-19?* Archivos De Bronconeumología, 57, 15–16. <https://doi.org/10.1016/j.arbres.2020.10.008>
- Degnan, A. J., Ghobadi, E. H., Hardy, P., Krupinski, E., Scali, E. P., Stratchko, L., Ulano, A., Walker, E., Wasnik, A. P., & Auffermann, W. F. (2019). *Perceptual and interpretive error in diagnostic radiology—causes and potential solutions*. Academic Radiology, 26(6), 833–845. <https://doi.org/10.1016/j.acra.2018.11.006>
- Extremo, A. (2021). *Estudio de algoritmos de redes neuronales convolucionales en dataset de imágenes médicas*. uvadoc.uva.es. UVA. <https://uvadoc.uva.es/handle/10324/47137>
- Facal de Castro, F., Estanislao, A., & Delfina, D. (2019). *El error diagnóstico en radiología. Análisis de variables explicativas* (tesis). Universidad de Valencia, Valencia.
- Gálvez M, M., & Montoya M, C. (2017). *Error en el informe radiológico: La Paradoja del Elefante en la habitación y Otros Tropiezos*. Revista Chilena De Radiología, 23(2), 80–89. <https://doi.org/10.4067/s0717-93082017000200008>
- Gálvez, M. (2016). *Calidad en radiología y el cambio en los últimos años*. Revista Chilena De Radiología, 22(3), 97. <https://doi.org/10.1016/j.rchira.2016.09.003>
- García M., C. (2003). *Anatomía del error en Radiología*. Revista Chilena De Radiología, 9(3). <https://doi.org/10.4067/s0717-93082003000300006>
- Garland, L. H. (1949). *On the scientific evaluation of Diagnostic Procedures*. Radiology, 52(3), 309–328. <https://doi.org/10.1148/52.3.309>

- Gorospe-Sarasúa, L., Muñoz-Olmedo, J. M., Sendra-Portero, F., & de Luis-García, R. (2022). *Retos de la Formación en radiología en la era de la inteligencia artificial*. *Radiología*, 64(1), 54–59. <https://doi.org/10.1016/j.rx.2020.10.003>
- Itri, J. N., Tappouni, R. R., McEachern, R. O., Pesch, A. J., & Patel, S. H. (2018). *Fundamentals of diagnostic error in imaging*. *RadioGraphics*, 38(6), 1845–1865. <https://doi.org/10.1148/rg.2018180021>
- Joison, A., Barcudi, R., Majul, E., Ruffino, S., De Matero Rey, J., Joison, A., Baiardil, G. (2021). *La Inteligencia artificial en la Educación Médica y la predicción en salud*. *Methodo. Investigación Aplicada a Las Ciencias Biológicas*, 6(1). [https://doi.org/10.22529/me.2021.6\(1\)07](https://doi.org/10.22529/me.2021.6(1)07)
- Kim, Y. W., & Mansfield, L. T. (2014). *Fool me twice: Delayed diagnoses in radiology with emphasis on perpetuated errors*. *American Journal of Roentgenology*, 202(3), 465–470. <https://doi.org/10.2214/ajr.13.11493>
- Kohn, L. T. (2009). *To err is human: Building a safer health system*. National Academy Press.
- Liu, C., Wang, B., Jiao, Q., & Zhu, M. (2019). *Reducing false positives for lung nodule detection in chest X-rays using cascading CNN*. 2019 14th IEEE Conference on Industrial Electronics and Applications (ICIEA). <https://doi.org/10.1109/iciea.2019.8833699>
- Machacado-Rojas, A. M., & Aparicio-Pico, L. E. (2021). *Técnicas de Inteligencia artificial aplicadas Al Análisis de Imágenes Diagnóstico*. *Eco Matemático*, 12(2). <https://doi.org/10.22463/17948231.3237>

Makary, M. A., & Daniel, M. (2016). *Medical error—the third leading cause of death in the US.*

BMJ, i2139. <https://doi.org/10.1136/bmj.i2139>

Malberti, M., Beguerí, G., Klenzi, R., & Ortega, M. (2021, April). *VISUALIZANDO LA*

INFORMACIÓN EN CIENCIA DE DATOS. sedici.unlp.edu.ar/. UNPL.

<http://sedici.unlp.edu.ar/handle/10915/120126>

Moawad, A. W., Fuentes, D. T., ElBanan, M. G., Shalaby, A. S., Guccione, J., Kamel, S.,

Jensen, C. T., & Elsayes, K. M. (2022). *Artificial Intelligence in diagnostic radiology:*

Where do we stand, challenges, and opportunities. *Journal of Computer Assisted*

Tomography, 46(1), 78–90. <https://doi.org/10.1097/rct.0000000000001247>

Mota Martínez, J., Facal De Castro, F., & Mirón Mombiela, R. (2018). *Errores diagnósticos:*

entendiendo los conceptos a través de ejemplos de columna. Seram. Piper.

<https://www.piper.espacio-seram.com/index.php/seram/article/view/1188>

Nam, J. G., Park, S., Hwang, E. J., Lee, J. H., Jin, K.-N., Lim, K. Y., Vu, T. H., Sohn, J. H.,

Hwang, S., Goo, J. M., & Park, C. M. (2019). *Development and validation of deep*

learning-based automatic detection algorithm for malignant pulmonary nodules on chest

radiographs. *Radiology*, 290(1), 218–228. <https://doi.org/10.1148/radiol.2018180237>

Onder, O., Yarasir, Y., Azizova, A., Durhan, G., Onur, M. R., & Ariyurek, O. M. (2021). *Errors,*

discrepancies and underlying bias in radiology with case examples: A pictorial review.

Insights into Imaging, 12(1). <https://doi.org/10.1186/s13244-021-00986-8>

- Pérez, E., Guzmán, R., Lozano, J., Torres, M., & Guzmán, R. (2022). *Classification of medical images using machine learning*. *DYNA*, 97(1), 35–38. <https://doi.org/10.6036/10117>
- Potchen, E. J. (2006). *Measuring observer performance in chest radiology: Some experiences*. *Journal of the American College of Radiology*, 3(6), 423–432. <https://doi.org/10.1016/j.jacr.2006.02.020>
- Puentes, G., Miranda, E., & Triana, G. (2021, noviembre). *Inteligencia artificial y radiología: la disrupción tecnológica en la transformación de un paradigma*. *revistamedicina.net*. *Revista Medicina*. <https://www.revistamedicina.net/index.php/Medicina/article/view/1648/2138>
- Raschio A., E., Contreras R., C., Allende N., F., & Maturana Q., P. (2021). *Inteligencia artificial: Desarrollo de Algoritmos de Clasificación y segmentación en radiografía de Tórax*. *Revista Chilena De Radiología*, 27(1), 8–16. <https://doi.org/10.4067/s0717-93082021000100008>
- Rossi, S., & Miguel, J. (2004). *Aplicaciones clínicas digital de imágenes médicas*. *Rev Med Clin Condes*, 15(2), 43–52.
- Rouhiainen, L. (2020). *Inteligencia artificial: 101 cosas que debes saber hoy sobre nuestro futuro*. Alienta.
- Sabih, D.-e-, Sabih, A., Sabih, Q., & Khan, A. N. (2010). *Image perception and interpretation of abnormalities; can we believe our eyes? can we do something about it?* *Insights into Imaging*, 2(1), 47–55. <https://doi.org/10.1007/s13244-010-0048-1>

- Santos, Á. M. (2022). *Gestión de Riesgos del Informe radiológico. Especial Referencia al error diagnóstico*. Radiología, 64, 194–206. <https://doi.org/10.1016/j.rx.2022.01.012>
- Sarmiento Barón, S y García Ruiz, J. (2021). *Aplicación de las técnicas de aprendizaje automático para la ubicación y detección temprana de tumores cerebrales*. Universidad de los Andes.
- Sarraf, S., DeSouza, D. D., Anderson, J., & Tofighi, G. (2016). *DeepAD: Alzheimer's disease classification via deep convolutional neural networks using MRI and fmri*. Alzheimer's Disease Neuroimaging Initiativ. <https://doi.org/10.1101/070441>
- Toquero, M. (2021). *Clasificación de Imágenes Médicas de Rayos-X mediante Redes Neuronales Convolucionales*. uvadoc.uva.es. UVA. <https://uvadoc.uva.es/handle/10324/50444>
- Ventura Alfaro, C. E. (2018). *Errores de medición en la Interpretación Mamográfica por radiólogos*. Revista De Salud Pública, 20(4), 518–522. <https://doi.org/10.15446/rsap.v20n4.52035>