

**Evaluación de la precisión y automatización de técnicas de machine learning en la
predicción de enfermedades mediante imágenes médicas**

Iván Darío Higuera González

Asesor

Rafael Roberto Ruiz Escorcía

Universidad Nacional Abierta y a Distancia UNAD
Escuela de Ciencias Básicas Tecnología e Ingeniería ECBTI
Especialización en Ciencia de Datos y Analítica
2025

Nota de Aceptacion

Rafael Roberto Ruiz Escorcía

Jurado

Jurado

Dedicatoria

Dedico este trabajo a mi familia, por ser mi pilar y fuente constante de inspiración, apoyo y amor incondicional. A mis amigos, quienes siempre me alentaron a seguir adelante, y a todos aquellos que creyeron en mí, incluso en los momentos más difíciles.

Agradecimientos

Agradezco profundamente a la Universidad Nacional Abierta y a Distancia (UNAD) por brindarme las herramientas, el conocimiento y el espacio para crecer tanto personal como profesionalmente. Su modelo educativo me permitió desarrollar habilidades fundamentales para llevar a cabo este trabajo y avanzar en mi formación académica.

Extiendo mi gratitud a mis docentes, quienes, con su guía y experiencia, me acompañaron en este proceso de aprendizaje y fueron un faro de conocimiento. A mis compañeros de estudio, por el trabajo colaborativo y el apoyo mutuo que hicieron de este camino una experiencia enriquecedora.

Finalmente, agradezco a mi familia, cuyo amor y comprensión me han permitido superar cada desafío y avanzar con determinación. Su paciencia y sacrificios han sido mi mayor motivación para continuar y alcanzar este logro.

Resumen

El uso de técnicas de Machine Learning (ML) en el análisis de imágenes médicas ha optimizado significativamente el diagnóstico de enfermedades, aumentando la precisión y reduciendo los tiempos de respuesta en comparación con los métodos tradicionales. Esta monografía presenta un análisis comparativo de las principales técnicas de ML, como Redes Neuronales Convolucionales (CNN) y Máquinas de Soporte Vectorial (SVM), evaluando su capacidad para identificar patrones complejos, minimizar errores diagnósticos y mejorar la automatización en la toma de decisiones clínicas.

Mediante una revisión sistemática basada en el método PRISMA, se analizaron 30 estudios relevantes, empleando la herramienta QUADAS-2 para evaluar su calidad metodológica. Los resultados revelan que las CNN alcanzan una precisión superior al 90% en la detección de enfermedades como neumonía y cáncer de mama, mientras que las SVM han demostrado una eficacia del 85% en la clasificación de tumores malignos. Además, se identificó que las Redes Generativas Adversarias (GAN) contribuyen a la generación de imágenes médicas sintéticas, facilitando el entrenamiento de modelos en contextos con datos limitados.

Este estudio concluye que las técnicas de ML han transformado el diagnóstico médico, ofreciendo herramientas que permiten mejorar la detección temprana de enfermedades y optimizar la carga de trabajo de los profesionales de la salud. Finalmente, se presentan recomendaciones para la integración de estos métodos en entornos clínicos, destacando la necesidad de mejorar la interpretabilidad de los modelos y asegurar su implementación ética y regulada.

Palabras clave: Automatización, Diagnóstico médico, Imágenes médicas, Inteligencia Artificial, Machine Learning, Predicción de enfermedades.

Abstract

The use of Machine Learning (ML) techniques in the analysis of medical images has significantly optimized disease diagnosis, increasing accuracy and reducing response times compared to traditional methods. This monograph presents a comparative analysis of the main ML techniques, such as Convolutional Neural Networks (CNN) and Support Vector Machines (SVM), evaluating their ability to identify complex patterns, minimize diagnostic errors and improve automation in clinical decision-making.

Through a systematic review based on the PRISMA method, 30 relevant studies were analyzed, using the QUADAS-2 tool to assess their methodological quality. The results reveal that CNNs achieve an accuracy greater than 90% in the detection of diseases such as pneumonia and breast cancer, while SVMs have demonstrated an efficacy of 85% in the classification of malignant tumors. In addition, Generative Adversarial Networks (GAN) were identified as contributing to the generation of synthetic medical images, facilitating the training of models in contexts with limited data.

This study concludes that ML techniques have transformed medical diagnosis, offering tools that allow for improved early detection of diseases and optimizing the workload of health professionals. Finally, recommendations are presented for the integration of these methods in clinical settings, highlighting the need to improve the interpretability of the models and ensure their ethical and regulated implementation.

Keywords: Automation, Medical diagnostics, Medical imaging, Artificial Intelligence, Machine Learning, Disease prediction.

Tabla de Contenido

Introducción	12
Planteamiento del Problema	13
Formulación del Problema	14
Justificación	15
Objetivos	16
Objetivo General	16
Objetivos Específicos	16
Marco de Referencia	17
Estado del Arte	17
Marco Conceptual	21
Marco Teorico	23
Metodologia	27
Técnicas de ML en el Diagnóstico Médico	31
Importancia	31
Evolución	32
Imágenes Médicas en la Predicción de Enfermedades	33
Aplicación de la Metodología PRISMA	35
Descripción del Método	35
Criterios de Inclusión y Exclusión	36
Evaluación de Calidad (QUADAS-2)	40
Resultados	41
Identificación de las Principales Técnicas de ML	43

Algoritmos Supervisados	43
Redes Neuronales Convolucionales (CNN)	43
Máquinas de Soporte Vectorial (SVM).....	44
Otros Algoritmos Relevantes	44
Ventajas y Limitaciones	45
Algoritmos No Supervisados y Mixtos	46
Redes Auto-Encoder.....	46
Clustering K-Means	47
Ventajas y Limitaciones	47
Técnicas Emergentes.....	48
Redes Generativas Adversarias (GAN).....	48
Redes Neuronales Recurrentes (RNN).....	49
Meta-Learning	49
Ventajas y Limitaciones	49
Comparación de Técnicas de ML	50
Relación entre Técnicas y Enfermedades	51
Criterios de Análisis de las Técnicas de ML	54
Parámetros de Evaluación.....	54
Caracterización de las Técnicas de ML	59
Clasificación según el Tipo de Enfermedad.....	59
Clasificación según la Modalidad de Imagen Médica	61
Comparación en Base a los Criterios Definidos	66
Análisis de los Resultados y Efectos de la Caracterización.....	69

Relación entre Precisión y Automatización	69
Identificación de Limitaciones y Áreas de Mejora	72
Impacto Potencial en la Práctica Médica	74
Recomendaciones	79
Resumen de Hallazgos	79
Contribuciones del Estudio	81
Líneas de Investigación Futuras.....	82
Conclusiones.....	86
Referencias.....	88

Lista de Tablas

Tabla 1 <i>Resumen de Estudios Analizados y Criterios Evaluados</i>	38
Tabla 2 <i>Clasificación de Estudios según Nivel de Riesgo Utilizando QUADAS-2</i>	41
Tabla 3 <i>Comparación de Técnicas de ML en Imágenes Médicas</i>	51
Tabla 4 <i>Modalidades de Imagenes Medicas y Tecnicas de ML</i>	65
Tabla 5 <i>Comparación de las Técnicas de ML</i>	67
Tabla 6 <i>Limitaciones y Áreas de Mejora en ML Médico</i>	73

Lista de Figuras

Figura 1 <i>Diagrama PRISMA</i>	37
Figura 2 <i>Distribución de Estudios en la Metodología PRISMA</i>	39
Figura 3 <i>Relacion entre Tecnicas de ML y Enfermedades</i>	52
Figura 4 <i>Tecnicas de ML Aplicadas en Modalidades de Imagen Medica</i>	66
Figura 5 <i>Mapa de Calor de la Precisión de Técnicas de ML en Imágenes Médicas</i>	70
Figura 6 <i>Comparación de Errores en el Diagnóstico Tradicional vs. ML</i>	75

Introducción

En la actualidad, el avance de las técnicas de Machine Learning (ML) ha revolucionado el ámbito del diagnóstico médico mediante imágenes médicas. Estas herramientas han permitido desarrollar sistemas capaces de procesar grandes volúmenes de datos con rapidez y precisión, optimizando los tiempos de respuesta y reduciendo los errores en la detección de enfermedades. La aplicación de ML en la medicina no solo representa un cambio tecnológico, sino también un impacto significativo en la vida de los pacientes y en la eficiencia de los sistemas de salud.

En este contexto, la presente monografía tiene como objetivo principal analizar críticamente las técnicas de ML utilizadas en la predicción de enfermedades mediante imágenes médicas, considerando aspectos fundamentales como su precisión, automatización, aplicabilidad clínica y adaptabilidad a diferentes modalidades de imagen. Este análisis incluye una comparación detallada entre diferentes técnicas, como Redes Neuronales Convolucionales (CNN) y Máquinas de Soporte Vectorial (SVM), evaluando su desempeño en la identificación de patologías y su impacto en la toma de decisiones clínicas.

La importancia de este trabajo radica en su capacidad para ofrecer una perspectiva integral que sirva de guía tanto para investigadores como para profesionales de la salud interesados en integrar ML en sus prácticas. Además, este estudio busca aportar al desarrollo de soluciones tecnológicas que permitan enfrentar los retos actuales en el diagnóstico médico, como la necesidad de diagnósticos tempranos y la escasez de recursos especializados.

Planteamiento del Problema

La dependencia de la tecnología informática ha dado lugar al almacenamiento de muchos datos electrónicos en la industria de la atención sanitaria. Por ello, los expertos de la salud y los médicos se enfrentan a situaciones exigentes para investigar correctamente los signos y síntomas y percibir las enfermedades en una fase temprana. Sin embargo, se ha demostrado que la tecnología de Machine Learning (aprendizaje automático) es beneficiosa al brindar una plataforma inconmensurable en el campo médico para que los problemas de atención médica se puedan resolver sin esfuerzo y de manera expedita. La predicción de enfermedades es un sistema basado en Machine Learning que funciona principalmente de acuerdo con las imágenes médicas tomadas. La enfermedad se predice mediante algoritmos y la comparación de los conjuntos de imágenes presentadas. De acuerdo con, la organización de las Naciones Unidas (ONU) cuatro de cada diez pacientes de los servicios de atención primaria y ambulatoria padecen una enfermedad sin conocimiento como resultado de un error médico, pero el 80% de esos casos se pueden prevenir (ONU, 2019). Un estudio, realizado por Gasca et.al (2018) indica que la tasa media de error en la interpretación radiológica de los médicos, aunque sean especialistas es del 30%; asimismo, según Barnett y White (2023) resaltan que escasos análisis médicos son 100% precisos.

Otros estudios realizados por la Asociación Americana del Cáncer mencionan que “los estudios por imágenes pueden encontrar grandes grupos de células cancerosas; sin embargo, ningún estudio por imágenes puede mostrar una sola célula cancerosa o incluso unas pocas”. Dado que, “se necesitan millones de células para hacer que un tumor sea lo suficientemente grande para que se vea en un estudio por imágenes” (Cáncer, s. f.); Es por ello, que gracias a la combinación de inteligencia artificial (IA) y Machine Learning en la medicina se han disminuido

los errores en los diagnósticos a simple vista; puesto que, la IA está consiente de disminuir la reiteración de errores médicos y mejorar la exactitud diagnóstica a través de la integración, el análisis y la interpretación de información por algoritmos y software (Lanzagorta et.al, 2022); por su lado, ML aprueba procesar grandes volúmenes de datos, los cuales en muchos casos son complejos y multivariados; asimismo, consienten organizar modelos computacionales en salud para conseguir patrones novedosos y exactos en una imagen (Ruiz et.al, 2024).

En consecuencia, pasar desapercibida una enfermedad es la primera causa de fallecimientos y a pesar que un gran porcentaje de los diagnósticos no son confiables, las imágenes médicas son necesarias; según el instituto de ingeniería del conocimiento (IIC) se demostró que las buenas imágenes médicas son valiosas para realizar el diagnóstico, seguimiento y tratamiento de enfermedades precisas (IIC, 2020); por ello, se propone un estudio y análisis de las técnicas de Machine Learning, principalmente por su capacidad para analizar datos a gran escala; dado que, a medida que se acrecienta el volumen de información disponible, las máquinas de aprendizaje se vuelven cada vez más esenciales para producir conocimientos valiosos, predecir tendencias y optimizar el diagnóstico de enfermedades a tiempo y además, reduciendo la carga de trabajo de los médicos, disminuido errores, tiempos en el diagnóstico y mejorado el rendimiento en la predicción y detección de muchas más diversas enfermedades.

Formulación del Problema

¿Qué aspectos garantizan la precisión de las técnicas de Machine Learning en el diagnóstico de enfermedades por medio de imágenes médicas?

Justificación

La necesidad de indagar en el área de Machine Learning, es debido a que esta se encuentra en constante estudio por parte de investigadores, y actualmente está proporcionando información relevante a fin del desarrollo y potenciación de las técnicas de predicción de Machine Learning en la calificación de imágenes para prevenir enfermedades con mayor precisión y a tiempo para proponer un tratamiento acertado.

Machine Learning ha sido una innovación que está cambiando el mundo; dado que, según artículos publicados por noticias el Mundo por parte de Guerrero y Lucio en (2023), mencionaron que es un aliado que liberara a los médicos de cualesquiera tareas monótonas, como la observación de las imágenes médicas; asimismo, investigaron que, en la popularidad, hay un algoritmo que se está preparando para descubrir 13 tipos de cáncer y su tecnología ha llegado a 45.000 pacientes en todo el mundo. Otros artículos de noticias expresan que es capaz de determinar enfermedades tan bien como los médicos (Sáez, 2023); Por su parte, Álvarez et.al en (2020) mencionan que el uso de metodologías de Machine Learning se perfeccionaba el entre un 15-25% los pronósticos de cáncer.

Por lo tanto, el uso de Machine Learning está revolucionando la precisión del diagnóstico de imágenes médicas al mejorar la predicción de los resultados de los pacientes; por lo tanto, la vigente investigación no solo se encara en la realización de un estudio crítico de los procesos de Machine Learning que se han desarrollado con el fin de identificar, comparar y destacar las técnicas que mejor aprovechan el poder de los algoritmos y el estudio de datos para la interpretación de imágenes médicas; si no que, además pretende ofrecer una mirada integral sobre cómo afectan los recientes cambios tecnológicos automatizados en la medicina, que en efecto se ha convertido en un beneficio para la predicción de enfermedades.

Objetivos

Objetivo General

Analizar críticamente las técnicas de Machine Learning utilizadas en la predicción de enfermedades mediante imágenes médicas, considerando su precisión, automatización, aplicabilidad clínica y adaptabilidad a diferentes modalidades de imagen.

Objetivos Específicos

Identificar las principales técnicas de Machine Learning para el diagnóstico a través de imágenes médicas de enfermedades.

Clasificar los criterios de análisis que maneja cada técnica de Machine Learning para el diagnóstico a través de imágenes médicas.

Caracterizar las técnicas de Machine Learning utilizadas para el diagnóstico a través de imágenes médicas en base a los criterios definidos.

Analizar los efectos de la caracterización para la determinación del grado de precisión y automatización de las técnicas para el diagnóstico de enfermedades por medio de imágenes médicas.

Marco de Referencia

Estado del Arte

El uso de Machine Learning (ML) en la medicina ha revolucionado la forma en que se analizan y diagnostican enfermedades. En particular, las técnicas de ML han permitido automatizar el procesamiento de grandes volúmenes de datos provenientes de imágenes médicas como radiografías, tomografías computarizadas y resonancias magnéticas, logrando una mayor eficiencia en el diagnóstico y pronóstico de enfermedades (Shen, Wu y Suk, 2017). Estas herramientas son especialmente relevantes en el contexto actual, donde la demanda por diagnósticos rápidos y precisos sigue creciendo exponencialmente (Vega, Mora y Badilla, 2020).

Las técnicas de Machine Learning aplicadas a las imágenes médicas pueden dividirse en dos categorías principales:

Técnicas de ML Clásico: Incluyen clasificadores supervisados como Support Vector Machines (SVM) y Random Forest, los cuales han demostrado un rendimiento destacado en la clasificación de imágenes médicas y la identificación de patrones relevantes. Por ejemplo, Andrade Prado y Baez Bello (2020) realizaron un estudio comparativo en el que evaluaron la eficacia de diferentes clasificadores supervisados para identificar rasgos de cáncer de mama, logrando resultados prometedores.

Técnicas de Deep Learning: Las redes neuronales convolucionales (CNN, por sus siglas en inglés) se han convertido en la opción predominante debido a su capacidad para procesar y analizar datos visuales de alta complejidad. Latif et al. (2019) resaltaron que las CNN han superado a los métodos tradicionales en la detección de diversas patologías. Un ejemplo clave es el trabajo de Kermany et al. (2018), donde se desarrolló un modelo basado en deep learning que identificó enfermedades tratables mediante imágenes oftalmológicas con una precisión cercana al

96% En los últimos años, la investigación en ML para el análisis de imágenes médicas ha abordado una amplia variedad de enfermedades:

Cáncer: Tecnologías como las redes neuronales han permitido una detección más temprana y precisa del cáncer de mama y otros tipos de tumores. Estudios como el de Pérez Córdova (2021) han explorado biomarcadores específicos mediante ML, mientras que Monroy Franco et al. (2021) utilizaron modelos predictivos basados en deep learning para evaluar riesgos asociados al cáncer. Además, Santamaría Santisteban y Siesquén Valdivia (2024) desarrollaron un sistema inteligente basado en deep learning para el diagnóstico del cáncer de próstata, demostrando avances en esta área específica.

Enfermedades Neurodegenerativas: El Alzheimer y otras patologías del sistema nervioso central han sido objeto de estudios detallados. Paniza (2020) demostró que el uso de resonancias magnéticas combinadas con algoritmos de deep learning puede mejorar la detección temprana de esta enfermedad.

COVID-19: Durante la pandemia, ML se utilizó extensivamente para desarrollar sistemas automáticos de diagnóstico a partir de imágenes torácicas. García et al. (2020) presentaron un modelo basado en deep learning para analizar radiografías de pacientes sospechosos de COVID-19, logrando alta precisión en los diagnósticos.

Uno de los enfoques más destacados en el desarrollo de técnicas de ML para imágenes médicas es la comparación de su eficiencia y nivel de automatización. Elyan et al. (2022) analizaron las capacidades de diferentes algoritmos para identificar patrones en imágenes médicas, concluyendo que los modelos de deep learning son significativamente más precisos y automatizados en tareas complejas, aunque requieren más tiempo de entrenamiento y mayor capacidad computacional. Por otro lado, estudios como el de Fernández Cobas (2021) han

explorado cómo optimizar estos sistemas para reducir la necesidad de intervención humana. Madriz et al. (2024) también destacan en una revisión actual que la integración de la inteligencia artificial en el diagnóstico médico está aumentando la eficiencia de los sistemas, aunque persisten retos técnicos.

A pesar de los avances en la aplicación de ML al diagnóstico médico, diversos estudios presentan limitaciones significativas que esta monografía busca abordar:

Falta de Generalización de los Modelos: Beaulieu Jones et al. (2019) destacan que muchos modelos de ML están diseñados para contextos específicos y pueden fallar al aplicarse a diferentes poblaciones o modalidades de imagen. Este estudio explora enfoques para mejorar la capacidad de generalización de los modelos, asegurando su aplicabilidad en diversos entornos clínicos.

Interpretabilidad de los Resultados: Un desafío clave es la falta de transparencia en los modelos de deep learning. Esta monografía analiza técnicas para mejorar la interpretabilidad, como los mapas de activación y los métodos de explicabilidad basados en inteligencia artificial.

Ética y Regulación: Lanzagorta Ortega et al. (2022) señalan la importancia de garantizar la privacidad de los datos de los pacientes, especialmente en un contexto donde la regulación sobre inteligencia artificial y salud aún está en desarrollo. En esta monografía se discuten estrategias para cumplir con normativas éticas y regulatorias en la implementación de ML en entornos clínicos.

Comparación de Técnicas Existentes: Aunque varios estudios han evaluado individualmente métodos como CNN y SVM, pocos han realizado una comparación sistemática de su desempeño en múltiples tipos de imágenes médicas. Este trabajo ofrece una revisión

exhaustiva basada en PRISMA, proporcionando un análisis comparativo que identifica fortalezas y debilidades de cada técnica.

El futuro de ML en el área de la salud incluye el desarrollo de biomarcadores innovadores y el uso de datos sintéticos para entrenar modelos más robustos. Cañaverall Uribe (2024) presentó un estudio sobre cómo sintetizar imágenes de mama mediante deep learning, una herramienta prometedora para mejorar la calidad de los diagnósticos. Ferrer Andreu (2024) demostró la validación de técnicas de deep learning en la detección de lesiones displásicas en pacientes con enfermedades inflamatorias intestinales. Además, las tecnologías emergentes, como la computación cuántica, podrían transformar la capacidad de procesamiento en el análisis de grandes volúmenes de datos (Biamonte et al., 2017).

El uso de Machine Learning en el análisis de imágenes médicas ha demostrado ser una herramienta eficaz para mejorar la precisión y la automatización en el diagnóstico de enfermedades. Aunque existen retos significativos, los avances recientes y las tendencias futuras sugieren un panorama prometedor, con un impacto potencialmente transformador en la práctica clínica y la salud pública. Esta monografía contribuye al área al abordar las limitaciones de estudios previos y ofrecer estrategias para optimizar la implementación de estas tecnologías en entornos médicos reales.

La monografía no realiza experimentación propia, pero busca superar las limitaciones identificadas en estudios previos mediante:

Revisión Comparativa: Analiza críticamente las fortalezas y debilidades de distintas técnicas de ML (CNN, SVM, Random Forest, etc.).

Propuesta de Criterios de Evaluación: Identifica métricas clave (precisión, automatización, interpretabilidad) para mejorar la selección de modelos en entornos clínicos.

Recomendaciones para Implementación Clínica: Sugiere cómo adaptar los modelos de ML en hospitales, abordando desafíos como calidad de datos y explicabilidad de algoritmos.

Uso de Datos Sintéticos (GAN): Destaca que la generación de imágenes sintéticas puede solucionar la escasez de datos etiquetados, problema recurrente en estudios previos.

Optimización de Modelos: Evalúa técnicas emergentes como Meta-Learning para reducir la dependencia de grandes volúmenes de datos y mejorar la eficiencia computacional.

Esta monografía no solo expone los avances y limitaciones de ML en imágenes médicas, sino que también propone estrategias para mejorar la precisión diagnóstica, optimizar el uso de datos y facilitar la integración de estas técnicas en la práctica clínica.

Marco Conceptual

Algoritmo: “Es un procedimiento utilizado para resolver un problema o realizar un cálculo. Los algoritmos actúan como una lista exacta de instrucciones que realizan acciones específicas paso a paso en rutinas basadas en hardware o software”; estos, “se utilizan ampliamente en todas las áreas de TI” y además, “en matemáticas, programación informática e informática, un algoritmo suele referirse a un pequeño procedimiento que resuelve un problema recurrente” (Gómez, s.f); asimismo, “los algoritmos también se utilizan como especificaciones para realizar el procesamiento de datos y desempeñan un papel importante en los sistemas automatizados”. (Gillis, s.f)

Deep Learning o Aprendizaje Profundo (DL): “El aprendizaje profundo es un subconjunto del aprendizaje automático” (Shinde y Shah, 2018); puesto que, “es un tipo de machine learning que entrena a una computadora para que realice tareas como las hacemos los seres humanos, como el reconocimiento del habla, la identificación de imágenes o hacer predicciones” (Loncolimma, 2016); Dado que, “en lugar de organizar datos para que se ejecuten

a través de ecuaciones predefinidas, el deep learning configura parámetros básicos acerca de los datos y entrena a la computadora para que aprenda por cuenta propia reconociendo patrones mediante el uso de muchas capas de procesamiento”. (SAS, s.f)

Inteligencia Artificial (IA): Es “la habilidad de los ordenadores para hacer actividades que normalmente requieren inteligencia humana” (Rouhiainen, 2018); de esta forma, tenemos que “el aprendizaje automático (ML) es una rama específica de la inteligencia artificial (IA)”; en sí, “Machine Learning tiene un alcance y un enfoque limitados en comparación con la IA”; puesto que, “la IA incluye varias estrategias y tecnologías que están fuera del alcance del aprendizaje automático”. Todos los programas de Machine Learning pueden considerarse parte de la Inteligencia Artificial, pero no toda la Inteligencia Artificial es Machine Learning. Están inherentemente relacionados, pero esto no significa que sean sinónimos. (Ricardo, 2021)

Machine Learning (ML): Igualmente llamada “aprendizaje automático o aprendizaje de máquinas, más conocido en el mundo actual como el machine learning, que es un subcampo de las ciencias de la computación y una rama de la inteligencia artificial cuya finalidad es desarrollar técnicas que permitan a las computadoras aprender, convirtiéndose en un pilar fundamental para el trato de datos a gran escala” (Hinestroza, 2018); por sí mismos, “los algoritmos de aprendizaje automático están entrenados para encontrar relaciones y patrones en los datos”, a causa de que, “utilizan datos históricos como entrada para hacer predicciones, clasificar información, agrupar puntos de datos, reducir la dimensionalidad e incluso ayudar a generar contenido nuevo”. (Tucci, s.f)

Modelo de entrenamiento: “Es un conjunto de datos que se utiliza para entrenar un algoritmo de ML. Consiste en los datos de salida de muestra y los conjuntos correspondientes de datos de entrada que influyen en la salida”; del mismo modo, “el modelo de entrenamiento se

utiliza para ejecutar los datos de entrada a través del algoritmo para correlacionar la salida procesada con la salida de muestra". (Oden.io, s. f.).

Marco Teorico

Machine Learning es una ciencia en perfeccionamiento de los algoritmos computacionales que están diseñados para emular la inteligencia humana estudiando del entorno circundante (El Naqa y Murphy, 2015) y el Deep Learning es un subconjunto del aprendizaje automático (Díaz, 2021); de allí que, el aprendizaje es un proceder humano natural que del mismo modo se ha transformado en un aspecto fundamental de las máquinas; por lo que, existen diversas técnicas ideadas para lo mismo (Biamonte et.al, 2017); es por ello, que los algoritmos usuales de aprendizaje automático se han aplicado en numerosas áreas de aplicación.

El uso de aplicaciones de aprendizaje automático relacionadas con la salud está aumentando rápidamente logrando afectar positivamente el campo de la atención médica (Beaulieu, 2019); por lo tanto, posee la fortaleza de reformar los sistemas de salud, a través de las observaciones de millones de datos clínicos se consiguen crear modelos con buenos pronósticos, de tamizaje y dictámenes (Vega et.al, 2020),

El tremendo éxito de los algoritmos de aprendizaje automático en tareas de reconocimiento de imágenes en los últimos años se cruza con una época de uso dramáticamente mayor de registros médicos electrónicos y diagnóstico por imágenes (ker, J et.al, 2017) donde esta revisión presenta los algoritmos de aprendizaje automático aplicados a las observaciones de imágenes médicas, centrándose en las redes neuronales convolucionales y enfatizando los aspectos clínicos del campo (Li. M et.al., 2023). La ventaja del aprendizaje automático en una era de big data médicos es que se pueden descubrir relaciones jerárquicas significativas dentro de los datos algorítmicamente sin una laboriosa elaboración manual de características (Shen. D

et.al., 2017); a partir de estos algoritmos, se cubren áreas de investigación clave y aplicaciones de clasificación, localización, detección, segmentación y registro de imágenes médicas. (Cañaverall, 2024). En definitiva, el reciente desarrollo en las áreas de aprendizaje automático, profundo y redes neuronales convolucionales profundas ha progresado y avanzado significativamente en la ciencia en tendencia de la visión por computadora (CV) y el análisis y la comprensión de imágenes (Elyan, 2022): de esta forma, Latif et.al., (2019) resalta que “los algoritmos de aprendizaje automático y profundo son formas importantes en las imágenes médicas para predecir los síntomas de la enfermedad temprana”. Las técnicas de aprendizaje profundo, en redes convolucionales específicas, han desarrollado rápidamente una metodología especial para la investigación de imágenes médicas (Kermany, 2018). Pedrero et.al, (2021) indica que “los procesos asociados a la atención sanitaria generan una gran cantidad de información difícil de analizar mediante procedimientos estadísticos estándar”; además, resalta que “disciplinas como la Ciencia de Datos cobraron relevancia, principalmente a través de estrategias como el Machine Learning (ML)” (p. 21)

En cuanto a la interpretación de imágenes por parte de un perito médico, esta es bastante limitada debido a su subjetividad y complejidad de las imágenes (Razzak, 2018); en consecuencia, estos algoritmos han servido para aumentar aún más la precisión y reducir aún más las tasas de falsos positivos y falsos negativos en los diagnósticos médicos, se han aprovechado los avances recientes en inteligencia artificial (IA) para desarrollar software capaz de ayudar en la práctica clínica (Loaiza, 2021). Las técnicas de Machine Learning han logrado un éxito significativo en el análisis de imágenes médicas debido a los algoritmos avanzados que permiten la extracción automatizada de características mejoradas; de modo que, Pillai (2021) indica, que se pueden analizar “varios tipos de imágenes médicas, incluidas resonancias

magnéticas, tomografías computarizadas, rayos X y portaobjetos de histopatología, para dilucidar el potencial de los modelos de aprendizaje profundo para mejorar la precisión del diagnóstico, la planificación del tratamiento y los resultados generales de los pacientes” (p. 48)

La proliferación de tecnologías de aprendizaje automático y análisis de imágenes en la atención sanitaria ha hecho que el descubrimiento prematuro de enfermedades sea posible, incluida “la detección temprana del retinoblastoma, una forma de cáncer ocular que afecta a los niños y puede ser mortal si se deja sin ser detectado” (Mistry y Ramakrishnan, 2023); asimismo, ayudó al diagnóstico preciso y oportuno del COVID-19 (Montazari et.al., 2021; García, 2020; Monroy et.al., 2021; Aguirre, 2023; Lopez et.al., 2023), por medio de la observación de imágenes de rayos X del tórax de un paciente (Pérez et.al, 2021) otra enfermedad relacionada es el diagnóstico de neumonía “Deep learning es capaz de clasificar si un paciente padece o no neumonía a partir de una imagen radiográfica de tórax” (Sánchez, 2020; Zhou, 2023), asimismo durante el desarrollo de su proyecto Pérez et.al, (2021) señala que “procesar manualmente un grupo de imágenes de pacientes lleva mucho tiempo, por lo que procesar grandes volúmenes de imágenes hace imposible tratar rápidamente a los pacientes si se detecta el virus” (p. 24)

Otras aplicaciones interesantes y de las más estudiadas han sido el descubrimiento de alzheimer por medio de imágenes médicas usando machine learning (Segura, 2019; Fernández, 2021; Poveda, 2023; Sanz, 2020; Paniza, 2020), la detección de cáncer de seno (Ruiz y Domínguez, 2022; Alcalá, 2022; González, 2021; Andrade y Báez, 2020; Páez et.al, 2023; Ardon, 2023; Robles y Millán, 2020; Lucena, 2023), cáncer de cuello uterino (Ortiz, 2022; Flores y Dueñas, 2019), cáncer de endometrio (Shallcrass, 2020), tumores cancerígenos (Bodadilla, 2021), cáncer colorrectal (Domínguez, 2024) cáncer de vejiga (Esteve D, 2021),

enfermedades oculares (Zavaleta et.al., 2022), esclerosis lateral múltiple (ELA) (Gil Chong, 2022).

Es resaltar que, la máquina de vectores de soporte (SVM) como método de ML y la red neuronal convolucional (CNN) como método de DL suelen ser las técnicas más utilizadas para analizar y diagnosticar enfermedades por medio de imágenes (Ghaffar et.al., 2023; Anandaram et.al., 2024). De acuerdo con, Cifuentes et.al., (2019) al indicar que “la red neuronal convolucional cuenta con la habilidad para clasificar con una variedad bastante amplia en cuanto a identificación de imágenes se refiere, teniendo así la capacidad de llegar a aplicaciones mucho más complejas”; asimismo, (Palacios y Ayleen, 2021) señalan que en su proyecto gracias al entrenamiento con redes convoluciones se obtuvo una buena y optima predicción. De esta forma, la arquitectura CNN es especialmente útil para el reconocimiento y la clasificación de imágenes, así como para otras tareas de Machine Learning, porque pueden procesar grandes cantidades de datos y producir predicciones altamente precisas.

En definitiva, Machine Learning es importante porque brinda una visión de las tendencias en el comportamiento y los patrones de las imágenes y de esta forma logra diagnosticar una enfermedad, además de respaldar el perfeccionamiento de los métodos de entrenamiento de las técnicas.

Metodología

Para llevar a cabo un análisis crítico de las técnicas de Machine Learning aplicadas en la predicción de enfermedades mediante imágenes médicas, es fundamental adoptar un enfoque sistemático y estructurado. En este contexto, la metodología de revisión sistemática basada en el método PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) resulta adecuada para garantizar la rigurosidad en la identificación, selección y evaluación de estudios relevantes. Este enfoque no solo permite organizar la información disponible de manera eficiente, sino que también facilita el análisis comparativo de las técnicas empleadas en función de su precisión, automatización y aplicabilidad clínica.

A continuación, se presenta la metodología empleada en este trabajo, que abarca desde los criterios de inclusión y exclusión hasta el análisis y síntesis de los datos extraídos de la literatura científica.

1. **Diseño del estudio:** La presente monografía sigue una revisión sistemática basada en la metodología PRISMA, con el objetivo de identificar, clasificar y caracterizar las técnicas de Machine Learning (ML) utilizadas para la predicción de enfermedades mediante imágenes médicas. Esta revisión sistemática examina investigaciones primarias y secundarias relevantes publicadas en revistas científicas y conferencias especializadas

2. **Criterios de inclusión:** Los criterios de inclusión para los estudios a analizar se establecieron considerando diversas características. En primer lugar, se seleccionaron publicaciones científicas comprendidas entre los años 2017 y 2024, con el objetivo de garantizar la actualidad y relevancia de la información. Asimismo, se incluyeron investigaciones que implementaran técnicas de Machine Learning en el análisis de imágenes médicas, enfocándose en su aplicación para el diagnóstico de enfermedades. Finalmente, se consideraron aquellos

estudios que incorporaran métricas de rendimiento como precisión, sensibilidad y especificidad, entre otras, permitiendo así una evaluación objetiva de la efectividad de los modelos propuestos

3. Criterios de exclusión: Los criterios de exclusión para los estudios a analizar se establecieron con el fin de garantizar la relevancia y la rigurosidad de la selección. En este sentido, se descartaron aquellos estudios que no incluyeran resultados cuantitativos, ya que la ausencia de estos impide una evaluación objetiva del desempeño de los modelos. Asimismo, se excluyeron publicaciones que no tuvieran un enfoque en el diagnóstico a partir de imágenes médicas, dado que el propósito de la investigación es analizar el impacto del Machine Learning en esta área específica. Finalmente, no se consideraron trabajos que no describieran detalladamente las técnicas de Machine Learning utilizadas, pues dicha información es fundamental para comprender la metodología y reproducibilidad de los estudios.

4. Fuentes de información y búsqueda: La búsqueda de artículos científicos se realizó en las principales bases de datos académicas, tales como: PubMed, Science Direct, Redalyc, Dialnet, Scielo, Scopus, Web of Science. Además, se utilizan palabras clave como: "Machine Learning", "imágenes médicas", "diagnóstico de enfermedades", "deep learning", "predicción de enfermedades" y combinaciones de estos términos.

5. Proceso de selección: El proceso de selección de los estudios se llevó a cabo siguiendo las cuatro fases del diagrama de flujo PRISMA. En la fase de identificación, se realizó una búsqueda inicial de estudios relevantes en las bases de datos seleccionadas. Posteriormente, en la fase de selección, se eliminaron los estudios duplicados y se revisaron los títulos y resúmenes para determinar su pertinencia con respecto al objetivo de la investigación. Luego, en la fase de elegibilidad, se analizaron los textos completos de los estudios preseleccionados, aplicando los criterios de inclusión y exclusión previamente definidos. Finalmente, en la fase de

inclusión, se incorporaron en la revisión aquellos estudios que cumplieron con todos los criterios de elegibilidad, asegurando así la calidad y relevancia de los trabajos seleccionados

6. Extracción de Datos: Para cada estudio incluido en la revisión, se realizó un proceso de extracción de datos con el fin de recopilar información clave para el análisis. En primer lugar, se identificaron las técnicas de Machine Learning utilizadas en cada investigación. Asimismo, se registró el tipo de imágenes médicas analizadas, como resonancias magnéticas, tomografías y ultrasonidos, entre otras. También se documentaron las enfermedades objeto de diagnóstico en cada estudio. Además, se recopilaron las métricas de rendimiento empleadas, incluyendo precisión, sensibilidad y especificidad, para evaluar la efectividad de los modelos. Se consideró el tamaño del dataset utilizado, ya que influye en la robustez de los resultados. Por último, se identificaron los métodos de validación aplicados, tales como validación cruzada o hold-out, con el propósito de analizar la fiabilidad de los enfoques implementados.

7. Análisis y síntesis de resultados: Los datos extraídos serán organizados en tablas con el objetivo de facilitar la comparación entre las diferentes técnicas de Machine Learning empleadas en los estudios analizados. Además, se realizará una síntesis cualitativa de los resultados, clasificando las técnicas según criterios previamente definidos, como precisión, capacidad de automatización y aplicabilidad clínica. A partir de esta clasificación, se llevará a cabo un análisis crítico para identificar las ventajas y limitaciones de cada enfoque. En particular, se evaluará la eficiencia en la predicción, el nivel de automatización de los modelos y su robustez ante variaciones en los datos de entrada, permitiendo así una comprensión más profunda del impacto de estas técnicas en el diagnóstico basado en imágenes médicas.

8. Evaluación de la calidad de los estudios: Para asegurar la calidad de la revisión, se utiliza una escala de evaluación estandarizada, como QUADAS-2 (Quality Assessment of

Diagnostic Accuracy Studies), con el fin de evaluar la validez de los estudios incluidos en cuanto a sesgos, aplicabilidad y calidad metodológica.

9. Limitaciones: Se reconocen diversas limitaciones en la presente revisión que podrían influir en los resultados obtenidos. Una de ellas es la posible restricción en el acceso a ciertas bases de datos o estudios relevantes, lo que podría limitar la exhaustividad del análisis. Asimismo, se identifica la falta de homogeneidad en las métricas de evaluación utilizadas en los distintos estudios, lo que dificulta la comparación directa de los resultados y la extracción de conclusiones generalizables. Estas limitaciones deben ser consideradas al interpretar los hallazgos de la revisión.

Técnicas de ML en el Diagnóstico Médico

Este apartado presenta el marco conceptual que sustenta el uso de Machine Learning (ML) en el diagnóstico médico. Se analiza su importancia, el rol de las imágenes médicas y la evolución de las técnicas de ML, estableciendo la base para los capítulos posteriores.

Importancia

El Machine Learning (ML) ha revolucionado el diagnóstico médico al ofrecer herramientas que mejoran la precisión, la velocidad y la eficiencia en la detección de enfermedades. Estas técnicas permiten el análisis automatizado de grandes volúmenes de datos, como imágenes médicas, reduciendo significativamente los errores asociados con los métodos tradicionales. Según Beaulieu-Jones et al. (2019), ML proporciona capacidades predictivas y de clasificación que ayudan a los profesionales de la salud a tomar decisiones más informadas. Además, el uso de ML en la medicina no solo alivia la carga de trabajo de los especialistas, sino que también reduce los costos operativos y mejora los resultados clínicos al detectar patologías en etapas tempranas (Ruiz et al., 2024). Por ejemplo, algoritmos de aprendizaje profundo han demostrado ser tan efectivos como los médicos en el diagnóstico de enfermedades como el cáncer de mama y el Alzheimer (Pillai, 2021; Segura Morales, 2019). Esto refuerza el papel de ML como una herramienta imprescindible en la práctica médica moderna.

Un estudio reciente destaca la aplicación del ML en la identificación temprana de trastornos neurológicos. Investigadores del hospital Mount Sinai School de Nueva York han desarrollado un algoritmo de inteligencia artificial capaz de analizar patrones de sueño, como movimientos o vocalizaciones nocturnas, que podrían ser indicadores tempranos de demencia o Parkinson. Este enfoque permite una evaluación más precisa y personalizada, facilitando diagnósticos tempranos y tratamientos oportunos (Huffington Post, 2025). La integración de ML

en la medicina también ha mostrado beneficios en la predicción y prevención de enfermedades. El Instituto de Investigación Sanitaria y Biomédica de Alicante (ISABIAL) participa en el proyecto DENDRITE, que utiliza técnicas de inteligencia artificial para crear modelos predictivos del deterioro cognitivo. Este proyecto busca mejorar la detección precoz y personalizar los planes de tratamiento, demostrando el potencial del ML en la medicina preventiva (Cadena SER, 2025).

Evolución

Desde su aparición, las técnicas de ML han evolucionado significativamente, pasando de algoritmos básicos de clasificación a modelos avanzados de aprendizaje profundo. Inicialmente, los métodos tradicionales como las máquinas de vectores de soporte (SVM) y los bosques aleatorios (Random Forests) fueron los más utilizados en el análisis de datos médicos (Cifuentes et al., 2019). Estos métodos se basaban en características predefinidas, lo que limitaba su capacidad para procesar grandes volúmenes de datos no estructurados.

El desarrollo de redes neuronales profundas, especialmente las CNN, marcó un hito en la evolución del ML. Estas redes son capaces de extraer automáticamente características de los datos de entrada, eliminando la necesidad de intervención manual (Shen et al., 2017). En años recientes, tecnologías como las redes generativas adversarias (GAN) y las redes neuronales recurrentes (RNN) han ampliado aún más el alcance de ML en la medicina, permitiendo tareas como la síntesis de imágenes médicas y la predicción de la progresión de enfermedades (Ghaffar et al., 2023). Este progreso no solo ha mejorado la precisión de los diagnósticos, sino que también ha abierto nuevas posibilidades para el desarrollo de sistemas médicos autónomos y personalizados, que pueden adaptarse a las necesidades específicas de los pacientes (Elyan et al., 2022). Además, las GAN han permitido superar limitaciones relacionadas con la escasez de

datos médicos al generar imágenes sintéticas de alta calidad para entrenar modelos. Según Perona (2021), este avance ha sido crucial en campos como la radiología, donde la disponibilidad de datos anotados puede ser limitada. Asimismo, Ayala (2024) destaca que las redes neuronales recurrentes han demostrado ser efectivas en el análisis de datos temporales, como la progresión de enfermedades cardiovasculares, proporcionando diagnósticos más precisos y personalizados.

Otro aspecto significativo en la evolución de ML es su capacidad para integrar datos de múltiples fuentes, como imágenes médicas, historiales clínicos y datos genómicos. Vega, Mora y Badilla (2020) enfatizan que esta integración no solo mejora la precisión de los modelos, sino que también permite desarrollar sistemas predictivos que anticipan complicaciones antes de que se manifiesten clínicamente. Estas innovaciones están transformando la medicina al ofrecer herramientas más robustas y accesibles para los profesionales de la salud.

Imágenes Médicas en la Predicción de Enfermedades

Las imágenes médicas, como radiografías, resonancias magnéticas (MRI) y tomografías computarizadas (CT), son fundamentales para el diagnóstico de enfermedades. Estas técnicas proporcionan una visión detallada del cuerpo humano, permitiendo a los médicos identificar anomalías que podrían pasar desapercibidas en un examen físico. Según el Instituto de Ingeniería del Conocimiento (2020), las imágenes médicas son esenciales para clasificar, monitorear y tratar enfermedades con alta precisión. El uso de algoritmos de ML en el análisis de imágenes médicas ha mejorado significativamente su eficacia. Las redes neuronales convolucionales (CNN), en particular, son capaces de detectar patrones complejos en imágenes que serían difíciles de identificar para el ojo humano. Un ejemplo destacado es la detección de neumonía a partir de radiografías de tórax, donde las CNN lograron tasas de precisión superiores al 90% (Zhou, 2023).

Además, las imágenes médicas combinadas con ML han demostrado ser efectivas en la detección de enfermedades como el cáncer y el Alzheimer en etapas iniciales, lo que facilita intervenciones más oportunas y efectivas (Li et al., 2023; Fernández Cobas, 2021). Esta integración de tecnología y medicina está transformando la forma en que se diagnostican y tratan las enfermedades.

Un aspecto relevante es la capacidad de las imágenes médicas para integrarse con sistemas de aprendizaje profundo y generar diagnósticos más precisos. Dorado Díaz (2019) destaca que la aplicación de ML en cardiología ha permitido predecir la reestenosis tras la colocación de stents coronarios, optimizando así los tratamientos médicos. Por su parte, Melo Arias et al. (2020) subrayan que la inteligencia artificial ha sido crucial en la identificación de patologías respiratorias relacionadas con el COVID-19, mejorando tanto la velocidad como la precisión de los diagnósticos. Otro avance importante es el uso de técnicas de interpretabilidad en ML para explicar los resultados obtenidos a partir de imágenes médicas. Según Vellido (2020), la interpretabilidad es esencial para garantizar la confianza de los profesionales médicos al utilizar sistemas de inteligencia artificial. Esta característica no solo aumenta la aceptación de la tecnología, sino que también mejora la colaboración entre las máquinas y los especialistas en la toma de decisiones clínicas.

Aplicación de la Metodología PRISMA

La metodología PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) es ampliamente reconocida por su capacidad para estructurar revisiones sistemáticas de manera transparente y reproducible. En este estudio, se utilizó PRISMA para seleccionar y evaluar los estudios relevantes en el campo del Machine Learning aplicado al diagnóstico médico mediante imágenes médicas. Cabe destacar que los resultados obtenidos en esta monografía provienen exclusivamente del análisis de estudios previos y no de experimentación propia. Esta metodología garantizó que el proceso de selección fuera exhaustivo y objetivo, minimizando posibles sesgos.

Descripción del Método

La metodología PRISMA fue implementada en esta monografía para garantizar un enfoque sistemático, transparente y reproducible en la búsqueda, selección y evaluación de los artículos incluidos. Este método es ampliamente reconocido por su capacidad para minimizar sesgos y asegurar la calidad de las revisiones bibliográficas al analizar estudios relevantes de manera exhaustiva. El enfoque PRISMA se estructura en etapas clave que permiten organizar y depurar de forma eficiente la información recopilada, asegurando que los estudios seleccionados cumplan con los objetivos de la investigación. Estas etapas incluyen:

1. Identificación: Búsqueda exhaustiva de registros relevantes en bases de datos y otras fuentes.
2. Selección: Evaluación inicial de los registros identificados para descartar duplicados y estudios irrelevantes.
3. Elegibilidad: Revisión detallada de los estudios seleccionados en base a criterios de inclusión y exclusión predefinidos.

4. **Inclusión:** Integración de los estudios finales que cumplen con los requisitos establecidos.

Este proceso estructurado no solo permitió depurar los estudios más relevantes, sino que también aseguró que los resultados de la investigación estuvieran respaldados por evidencia confiable y de alta calidad. Gracias a la aplicación rigurosa de PRISMA, se logró construir una base sólida para los análisis y conclusiones presentados en esta monografía.

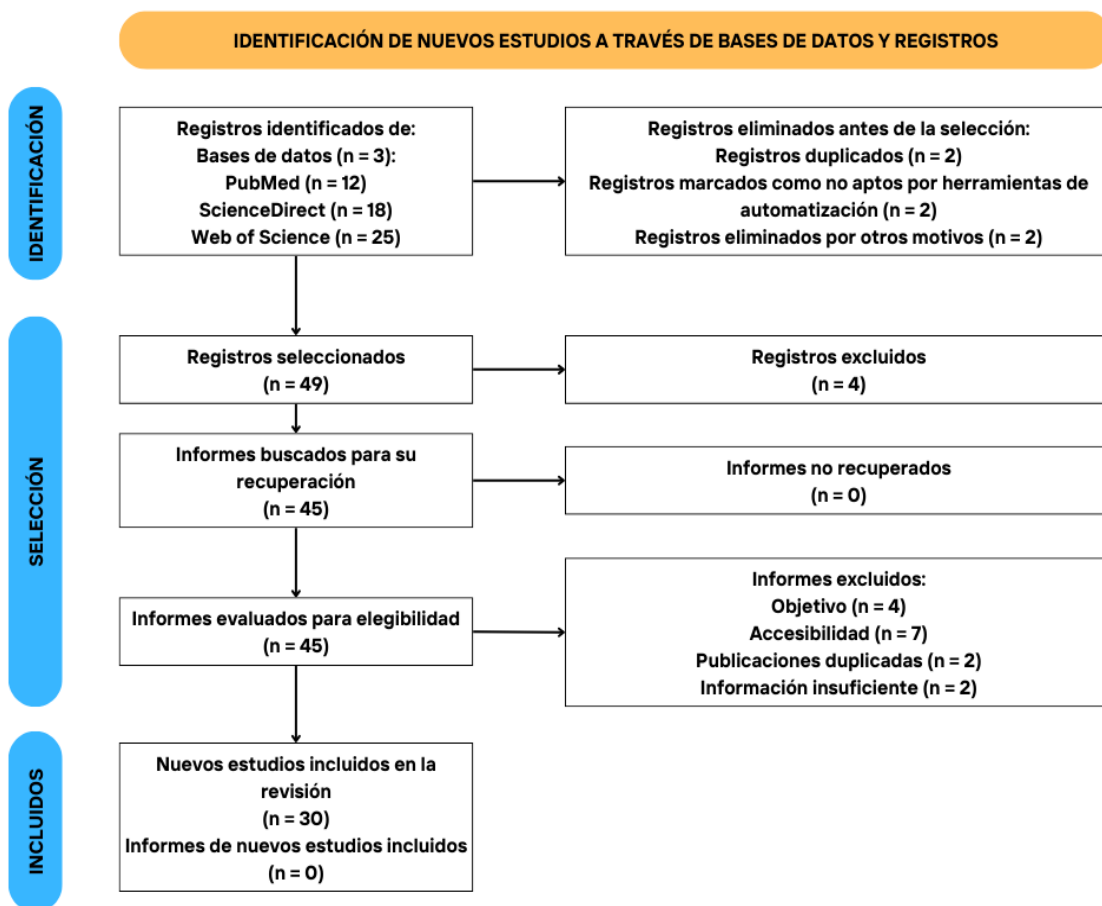
Criterios de Inclusión y Exclusión

Para garantizar la rigurosidad en la selección de los estudios, se establecieron criterios de inclusión y exclusión que permitieron filtrar las investigaciones más relevantes. Dentro de los criterios de inclusión, se consideraron publicaciones en español e inglés para asegurar un mayor alcance. Además, se incluyeron artículos científicos, tesis y revisiones sistemáticas, siempre que abordaran el uso de técnicas de Machine Learning en la predicción de enfermedades a partir de imágenes médicas. Asimismo, se priorizaron estudios que estuvieran disponibles en texto completo, permitiendo un análisis detallado de su contenido. Por otro lado, dentro de los criterios de exclusión, se descartaron publicaciones duplicadas, artículos que no contaran con acceso al texto completo y estudios que no abordaran directamente la aplicación de Machine Learning en imágenes médicas. Asimismo, se excluyeron aquellos documentos que no proporcionaran información suficiente para el análisis, garantizando así la validez de los resultados obtenidos en la revisión.

El proceso de selección se resume en la Figura 1 (Diagrama de flujo PRISMA). Este diagrama muestra las etapas del proceso, desde la identificación inicial de registros hasta la inclusión de los estudios finales. En total, se analizaron 55 estudios, de los cuales 30 cumplieron con los criterios establecidos.

Figura 1

Diagrama PRISMA



Este diagrama detalla las etapas de identificación, selección, elegibilidad e inclusión de los estudios, así como el número de registros eliminados en cada paso del proceso. A continuación, se presenta una descripción general de los resultados en cada etapa:

1. Identificación: Se localizaron un total de 55 registros provenientes de bases de datos como PubMed (n=12), ScienceDirect (n=18) y Web of Science (n=25).
2. Selección: Se excluyeron registros duplicados (n=2), no aptos por herramientas de automatización (n=2) y otros motivos (n=2).

3. Elegibilidad: De los 45 estudios evaluados, se excluyeron 15 por no cumplir con los criterios definidos: objetivo (n=4), accesibilidad (n=7), duplicados (n=2) e información insuficiente (n=2).

4. Inclusión: Finalmente, se incluyeron 30 estudios en la revisión.

De esta forma, el diagrama PRISMA ilustra el proceso de selección de los estudios incluidos en esta revisión sistemática. Cada etapa refleja los criterios de inclusión y exclusión aplicados para garantizar la calidad y relevancia de los artículos seleccionados. En la Tabla 1, se presenta un resumen detallado de este proceso, mostrando la cantidad de estudios identificados inicialmente, así como las razones por las cuales algunos fueron excluidos en las diferentes etapas de evaluación.

Tabla 1

Resumen de Estudios Analizados y Criterios Evaluados

Categoría	Cantidad de Estudios	Descripción
Estudios analizados inicialmente	55	Total de registros identificados en bases de datos
Estudios eliminados por duplicados	2	Eliminados en la etapa de selección
Estudios eliminados por criterios de accesibilidad	7	No disponibles en texto completo
Estudios eliminados por información insuficiente	2	No contenían detalles relevantes para el análisis
Estudios finales incluidos	30	Cumplieron todos los criterios establecidos

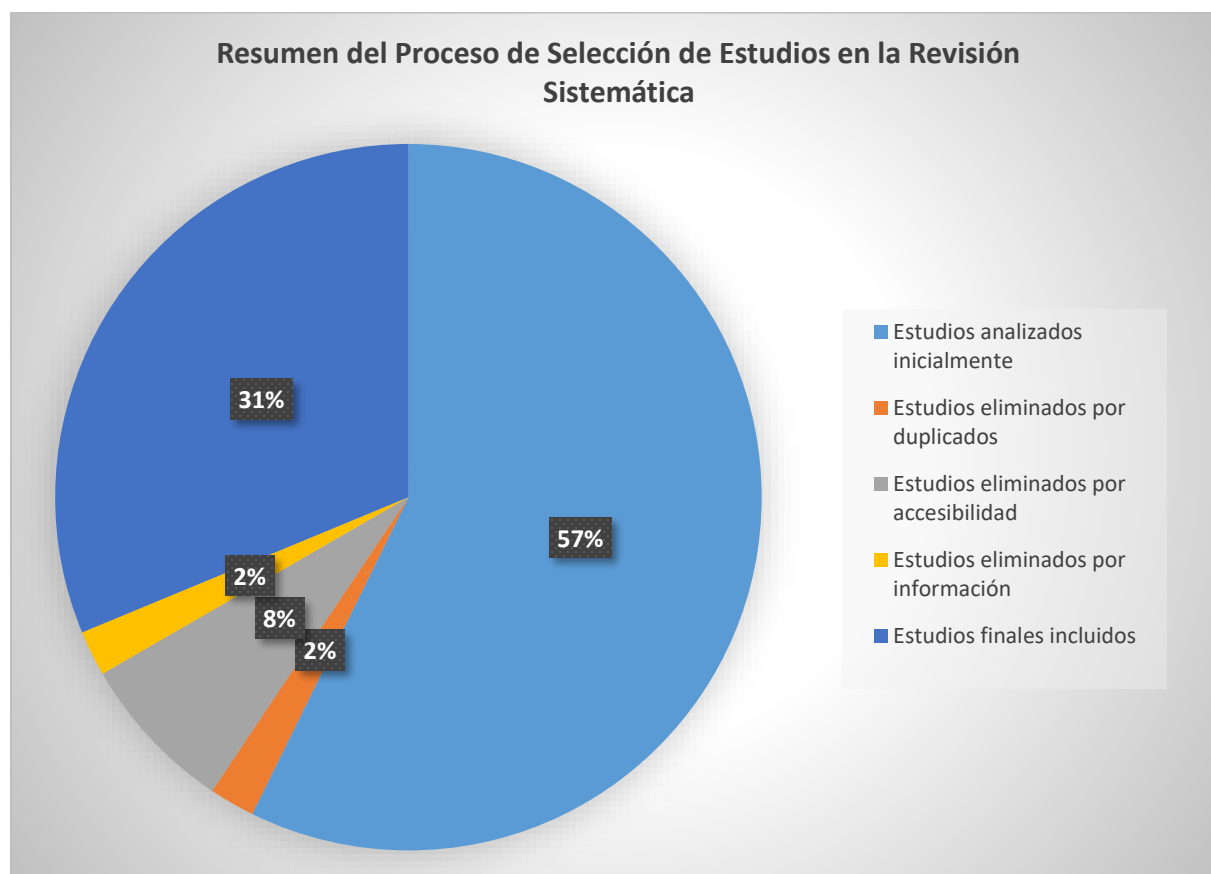
Nota. La tabla presenta un resumen del proceso de selección de estudios mediante la metodología PRISMA. Se identificaron inicialmente 55 estudios en bases de datos

especializadas, de los cuales 25 fueron excluidos en diferentes etapas por criterios de duplicidad, accesibilidad o insuficiencia de información. Finalmente, se incluyeron 30 estudios que cumplieron con todos los requisitos de inclusión, garantizando la relevancia y calidad de los datos analizados en esta revisión.

El siguiente gráfico representa la distribución porcentual de los estudios evaluados mediante la metodología PRISMA. En ella se destacan el número de registros identificados inicialmente, los criterios de exclusión aplicados en cada etapa del proceso y la cantidad final de estudios incluidos en el análisis.

Figura 2

Distribución de Estudios en la Metodología PRISMA



Este proceso permitió garantizar que los 30 estudios finales incluidos cumplieran con los criterios establecidos, asegurando la calidad metodológica y la pertinencia de los datos analizados en esta revisión.

Evaluación de Calidad (QUADAS-2)

Para garantizar la calidad y relevancia de los estudios seleccionados, se utilizó la herramienta QUADAS-2 (Quality Assessment of Diagnostic Accuracy Studies). Esta herramienta permite evaluar la validez interna y la aplicabilidad de los estudios en el contexto de investigaciones de diagnóstico, proporcionando una clasificación que facilita priorizar los estudios más relevantes. Cada estudio fue evaluado en función de diversos criterios para garantizar su calidad y relevancia dentro del análisis. En primer lugar, se consideró la representatividad de la población estudiada, verificando si la muestra utilizada era adecuada y relevante para el tema de interés. Además, se analizó la descripción detallada de las técnicas de Machine Learning utilizadas, asegurando que los estudios explicaran claramente los algoritmos implementados, los parámetros ajustados y las métricas empleadas para evaluar el rendimiento. También se evaluó la calidad y disponibilidad de los datos de entrada, revisando si las imágenes médicas empleadas eran de alta calidad, accesibles y apropiadas para los objetivos planteados. Por último, se analizaron los resultados de precisión y rendimiento, valorando las métricas reportadas, como sensibilidad, especificidad y AUC-ROC, y su coherencia con los métodos descritos en cada estudio.

Cada estudio fue clasificado en una de tres categorías según el nivel de riesgo asociado a su calidad metodológica y validez de los resultados. Se consideraron de bajo riesgo aquellos estudios que cumplieron de manera adecuada con todos los criterios establecidos, demostrando una sólida calidad metodológica y presentando resultados relevantes. Por otro lado, los estudios

fueron categorizados como de riesgo incierto cuando no proporcionaron información suficiente en uno o más criterios, lo que generó dudas sobre la validez de sus hallazgos. Finalmente, se clasificaron como de alto riesgo aquellos estudios que presentaron deficiencias significativas en múltiples criterios, lo que limitó su aplicabilidad y confiabilidad dentro del análisis.

Resultados

De los 30 estudios incluidos en el análisis:

- 18 estudios fueron clasificados como de bajo riesgo, ya que cumplieron con todos los criterios de manera clara y completa. Estos estudios proporcionaron resultados sólidos y detallados sobre el uso de técnicas de Machine Learning en el análisis de imágenes médicas.
- 8 estudios presentaron riesgo incierto, principalmente debido a la falta de detalle en la descripción de las técnicas utilizadas o en la calidad de los datos de entrada.
- 4 estudios se clasificaron como de alto riesgo, debido a deficiencias significativas en la representatividad de la población estudiada y en la disponibilidad de resultados de precisión claros.

La Tabla 2 resume la clasificación de los estudios según su nivel de riesgo, utilizando la herramienta QUADAS-2. Esta clasificación permitió evaluar la calidad metodológica de cada estudio, identificando aquellos con mayor rigor en sus procedimientos y resultados. La clasificación obtenida permitió priorizar los estudios con mayor calidad metodológica y relevancia en el análisis. Los estudios clasificados como de bajo riesgo fueron utilizados como base para desarrollar las conclusiones principales de esta revisión, mientras que los de riesgo incierto y alto riesgo se consideraron complementarios o secundarios, dependiendo de la información aportada. Cabe resaltar que esta evaluación se realizó sobre estudios previamente publicados y no sobre experimentos propios.

Tabla 2*Clasificación de Estudios según Nivel de Riesgo Utilizando QUADAS-2*

Nivel de riesgo	Número de estudios	Descripción
Bajo riesgo	18	Cumplen todos los criterios: población representativa, técnicas bien descritas, datos de calidad y resultados sólidos.
Riesgo incierto	8	Carecen de información suficiente en uno o más criterios, generando dudas sobre la validez de los resultados.
Alto riesgo	4	Presentan deficiencias significativas en varios criterios, limitando su aplicabilidad y confiabilidad.

Nota. La tabla muestra la clasificación de los estudios según el nivel de riesgo evaluado con QUADAS-2. Los criterios incluyen representatividad de la población, técnicas de Machine Learning, calidad de los datos y precisión de los resultados, permitiendo priorizar los estudios más relevantes.

Identificación de las Principales Técnicas de ML

En este apartado se identifican y describen las principales técnicas de Machine Learning (ML) utilizadas en el diagnóstico médico, clasificándolas en algoritmos supervisados, no supervisados y técnicas emergentes. El enfoque está en sus características específicas, aplicaciones más comunes y ventajas en el análisis de imágenes médicas.

Algoritmos Supervisados

Los algoritmos supervisados se basan en conjuntos de datos previamente etiquetados para entrenar modelos capaces de predecir clases o valores específicos. Estos algoritmos han demostrado ser altamente efectivos en tareas de clasificación y regresión, especialmente en diagnósticos asistidos por imágenes médicas. El desarrollo de estas herramientas ha sido crucial en la medicina moderna, permitiendo a los profesionales tomar decisiones informadas con base en datos de alta calidad. Además, Alfaro y Ospina (2021) enfatizan que la implementación de algoritmos supervisados ha reducido considerablemente los errores diagnósticos, mejorando la eficiencia en procedimientos médicos.

Redes Neuronales Convolucionales (CNN)

Las Redes Neuronales Convolucionales (CNN) son una de las técnicas más potentes para el análisis de imágenes médicas. Su arquitectura, inspirada en la corteza visual humana, permite extraer características jerárquicas de las imágenes, lo que las hace ideales para tareas como la clasificación y la segmentación de imágenes médicas (Shen et al., 2017). Además, estas redes son capaces de manejar datos no estructurados y extraer patrones complejos que superan la capacidad del ojo humano (Erickson et al., 2017). Las CNN han sido utilizadas con éxito en aplicaciones como:

- Diagnóstico de Neumonía: Según Zhou (2023), las CNN lograron tasas de precisión superiores al 90% al analizar radiografías de tórax.
- Detección de Cáncer de Mama: En estudios como el de Ruiz y Domínguez (2022), estas redes mostraron una reducción significativa de falsos positivos y negativos.
- Identificación de Alzheimer: Segura Morales (2019) informa una sensibilidad del 92% al analizar imágenes de resonancia magnética.

Máquinas de Soporte Vectorial (SVM)

Las Máquinas de Soporte Vectorial (SVM) son algoritmos supervisados que buscan encontrar un hiperplano óptimo para separar las clases dentro de los datos. Son particularmente útiles en el diagnóstico médico debido a su capacidad para manejar datos de alta dimensionalidad y conjuntos de datos más pequeños (Cifuentes et al., 2019). Asimismo, estas se emplean para tareas de clasificación binaria y multicategoría, mostrando una alta eficacia en contextos donde los datos etiquetados son limitados. En imágenes médicas, las SVM han sido empleadas para:

- Clasificación de Tumores. Gasca et al. (2018) informan que las SVM lograron precisiones superiores al 85% en la detección de tumores malignos en imágenes histológicas.
- Segmentación de Imágenes. Utilizadas para distinguir regiones específicas de interés en imágenes médicas, como tejido sano frente a tejido afectado por cáncer.
- Diagnóstico de Parkinson. Rincón Velásquez (2024) reporta que las SVM han sido utilizadas con éxito en la identificación de biomarcadores para el diagnóstico temprano de Parkinson.

Otros Algoritmos Relevantes

Otros algoritmos supervisados, como los Bosques Aleatorios (Random Forests) y los K-Nearest Neighbors (KNN), también han mostrado resultados prometedores:

Bosques Aleatorios: Ideales para la clasificación binaria, han sido utilizados en estudios para identificar enfermedades cardiovasculares y distinguir entre tejidos normales y anómalos en imágenes médicas (Pillai, 2021). Según Vega, Mora y Badilla (2020), esta técnica es especialmente efectiva en el análisis de conjuntos de datos médicos heterogéneos, ya que combina múltiples árboles de decisión para mejorar la precisión.

K-Nearest Neighbors: Aunque menos comunes, han demostrado ser efectivos en tareas específicas de clasificación cuando se dispone de un conjunto de datos pequeños y bien etiquetados.

Ventajas y Limitaciones

Los algoritmos supervisados se han consolidado como una herramienta esencial en la aplicación de Machine Learning (ML) en la medicina, debido a su capacidad para realizar predicciones precisas cuando se dispone de datos bien etiquetados. Una de sus principales ventajas es la posibilidad de resolver tareas de clasificación y regresión con altos niveles de precisión, lo que es especialmente útil en diagnósticos médicos asistidos por imágenes (Medrano Parado, 2017). Por ejemplo, las redes neuronales convolucionales (CNN) destacan por su capacidad para manejar grandes volúmenes de datos y extraer automáticamente características clave, eliminando la necesidad de intervención manual (Santamaría Santisteban y Siesquén Valdivia, 2024). Sin embargo, los algoritmos supervisados presentan limitaciones importantes. Uno de los principales desafíos es la necesidad de grandes volúmenes de datos de alta calidad para entrenar modelos efectivos. Esto puede ser un obstáculo en contextos clínicos donde los datos etiquetados son escasos o difíciles de obtener (Caicedo Cobos et al., 2024). Además, las CNN, aunque efectivas, requieren un alto poder computacional para procesar datos, lo que limita su aplicabilidad en entornos con recursos tecnológicos limitados (Santamaría Santisteban y

Siesquén Valdivia, 2024). Por otro lado, las máquinas de vectores de soporte (SVM) son eficientes en tareas de clasificación binaria y funcionan bien con datos de alta dimensionalidad. Sin embargo, su desempeño depende en gran medida de la calidad de las características preprocesadas, lo que puede ser un reto cuando se trabaja con datos no estructurados o ruidosos (Andrade Prado y Báez Bello, 2020). Además, las SVM tienden a ser menos escalables que otras técnicas, lo que las hace menos adecuadas para conjuntos de datos masivos.

En términos generales, los algoritmos supervisados ofrecen soluciones robustas y precisas para problemas médicos específicos, pero su efectividad está condicionada por la disponibilidad y calidad de los datos, así como por los recursos tecnológicos necesarios para su implementación. A pesar de estas limitaciones, siguen siendo una opción valiosa para aplicaciones médicas donde los datos etiquetados están disponibles y las tareas son bien definidas.

Algoritmos No Supervisados y Mixtos

Los algoritmos no supervisados no requieren datos etiquetados, lo que los hace útiles en contextos donde los datos son abundantes, pero carecen de anotaciones. Los algoritmos no supervisados no requieren datos etiquetados, lo que los hace ideales para explorar patrones desconocidos o realizar tareas de agrupamiento y reducción de dimensionalidad. Bastidas Rodríguez (2023) señala que estas técnicas han sido fundamentales en el análisis de datos genómicos y la segmentación de imágenes médicas. Entre estos algoritmos destacan las Redes Auto-Encoder y el Clustering K-Means:

Redes Auto-Encoder

Son utilizadas para reducir dimensionalidad y preentrenar modelos en conjuntos de datos no etiquetados antes de realizar tareas supervisadas (Shen et al., 2017). Asimismo, han sido

utilizados para la reducción de ruido en imágenes de tomografía computarizada (CT) y resonancia magnética (MRI).

Clustering K-Means

Aplicado en la segmentación de imágenes médicas, permite identificar patrones dentro de los datos y agrupar píxeles similares en imágenes de resonancia magnética y tomografías computarizadas. Además, métodos como el clustering K-Means han permitido identificar subgrupos en datos clínicos complejos, facilitando la personalización de tratamientos (Bravo et al., 2021). Por otro lado, los algoritmos mixtos, como las combinaciones de redes neuronales supervisadas y no supervisadas, están ganando relevancia en aplicaciones avanzadas, como la detección de anomalías en imágenes médicas sin necesidad de etiquetar previamente grandes cantidades de datos (Latif et al., 2019).

Ventajas y Limitaciones

Los algoritmos no supervisados presentan varias ventajas en el análisis de datos médicos, particularmente en contextos donde los datos etiquetados son escasos o inexistentes. Una de sus principales fortalezas es la capacidad para descubrir patrones ocultos y realizar agrupaciones sin depender de etiquetas predefinidas, lo que permite explorar grandes volúmenes de datos no estructurados. Según Bastidas Rodríguez (2023), estos algoritmos son fundamentales para identificar subgrupos en datos genómicos y segmentar imágenes médicas, facilitando análisis más detallados. Además, técnicas como el clustering K-Means y los autoencoders destacan por su versatilidad. El clustering permite agrupar datos similares, mientras que los autoencoders son efectivos en la reducción de ruido y la detección de anomalías en imágenes médicas, como resonancias magnéticas y tomografías computarizadas (Bravo et al., 2021). Vega, Mora y Badilla

(2020) señalan que estas técnicas son particularmente útiles en la personalización de tratamientos médicos basados en características específicas de los pacientes.

No obstante, los algoritmos no supervisados también enfrentan limitaciones importantes. Uno de los principales desafíos es la interpretación de los resultados, ya que, al no contar con etiquetas, los patrones identificados pueden carecer de un significado clínico claro sin un análisis adicional (Vellido, 2020). Además, estos métodos pueden ser sensibles a la calidad y cantidad de datos, lo que puede llevar a resultados menos confiables si los datos de entrada son ruidosos o insuficientes (Erickson et al., 2017). Por ejemplo, los resultados del clustering pueden variar significativamente dependiendo de los parámetros iniciales y el número de grupos definidos. Otra limitación es la dependencia de heurísticas para validar la calidad de los agrupamientos o las características extraídas, lo que puede introducir subjetividad en la interpretación (Ghaffar et al., 2023). A pesar de estas limitaciones, los algoritmos no supervisados siguen siendo una herramienta valiosa para el análisis exploratorio y la generación de hipótesis en la investigación médica.

Técnicas Emergentes

Estas técnicas emergentes están redefiniendo el futuro del diagnóstico médico, ofreciendo soluciones más adaptables y efectivas para enfrentar los desafíos clínicos modernos. Entre estas se destacan:

Redes Generativas Adversarias (GAN)

Utilizadas para la síntesis de imágenes médicas y la ampliación de conjuntos de datos pequeños, lo que mejora el entrenamiento de modelos supervisados (Ghaffar et al., 2023).

Redes Neuronales Recurrentes (RNN)

Aunque más comunes en el análisis de series temporales, las RNN han mostrado aplicaciones prometedoras en la predicción de la progresión de enfermedades utilizando imágenes médicas combinadas con datos clínicos longitudinales (Elyan et al., 2022).

Meta-Learning

Este enfoque emergente busca mejorar la capacidad de los modelos para aprender rápidamente de pequeños conjuntos de datos, una característica clave en el diagnóstico médico donde los datos pueden ser limitados (Li et al., 2023). Por otro lado, el meta-learning está ganando popularidad en escenarios donde los datos disponibles para entrenar son escasos, optimizando los tiempos de aprendizaje de los modelos (Dorado Díaz, 2019)

Ventajas y Limitaciones

Estas técnicas están ayudando a abordar problemas como la falta de interpretabilidad y la dependencia de grandes volúmenes de datos etiquetados, abriendo nuevas posibilidades para diagnósticos más precisos y efectivos (Madriz et al., 2024). Por ello, las técnicas emergentes en Machine Learning, como las redes generativas adversarias (GAN), el meta-learning y las redes neuronales recurrentes (RNN), han ampliado significativamente las aplicaciones del aprendizaje automático en la medicina. Estas técnicas destacan por su capacidad para abordar limitaciones tradicionales y abrir nuevas posibilidades en el análisis de datos médicos. Una de las principales ventajas de estas técnicas es su capacidad de adaptarse a entornos con datos limitados o no etiquetados. Por ejemplo, las GAN han revolucionado la generación de datos sintéticos, permitiendo crear imágenes médicas de alta calidad que mejoran el entrenamiento de modelos en contextos con escasez de datos reales (Ghaffar et al., 2023). Asimismo, el meta-learning permite a los modelos aprender rápidamente de pequeños conjuntos de datos, una característica esencial

en aplicaciones clínicas con datos restringidos (Dorado Díaz, 2019). Otra ventaja clave es la capacidad de estas técnicas para manejar datos complejos y heterogéneos. Según Vega, Mora y Badilla (2020), las RNN han demostrado ser especialmente efectivas en el análisis de series temporales, como la progresión de enfermedades cardiovasculares, facilitando diagnósticos más precisos y personalizados. Además, estas tecnologías han permitido mejorar la calidad de las imágenes médicas mediante la reducción de ruido y la ampliación de detalles, lo que incrementa la confianza en los resultados diagnósticos.

Sin embargo, las técnicas emergentes también enfrentan desafíos importantes. Una limitación destacada es su alta dependencia de recursos computacionales, lo que puede dificultar su implementación en centros médicos con infraestructura limitada (Vellido, 2020). Además, la complejidad de estas técnicas dificulta su interpretabilidad, lo que puede generar desconfianza entre los profesionales de la salud (Gutiérrez et al., 2022). Según Perona (2021), las GAN, aunque efectivas, pueden producir resultados inconsistentes si los modelos no están bien entrenados o los datos iniciales contienen sesgos. Otro desafío es la falta de estandarización en su aplicación clínica. Muchas de estas técnicas requieren ajustes personalizados según la enfermedad o el tipo de datos, lo que puede aumentar los costos y tiempos de implementación (Bravo et al., 2021). A pesar de estas limitaciones, las técnicas emergentes representan un avance significativo en la medicina, ofreciendo herramientas innovadoras para mejorar la precisión y eficiencia del diagnóstico médico.

Comparación de Técnicas de ML

A continuación, se presenta una tabla comparativa que resume el desempeño de las principales técnicas de ML utilizadas en el análisis de imágenes médicas.

Tabla 3*Comparación de Técnicas de ML en Imágenes Médicas*

Técnica	Aplicaciones	Precisión Promedio	Ventajas	Limitaciones
CNN	Diagnóstico de neumonía, cáncer, Alzheimer	90-95%	Alta precisión, extracción automática de características	Requiere gran cantidad de datos y recursos computacionales
SVM	Clasificación de tumores, segmentación de imágenes	80-85%	Funciona bien con datos pequeños y alta dimensionalidad	Sensible a la selección de parámetros
Random Forest	Clasificación de enfermedades cardiovasculares	85%	Manejo de datos heterogéneos, bajo riesgo de sobreajuste	Menos eficiente en datos no estructurados
K-Means	Agrupamiento en análisis genómicos	-	No requiere datos etiquetados	Difícil interpretar resultados

Nota. Los valores de precisión son aproximados y dependen de la base de datos utilizada y la configuración del modelo.

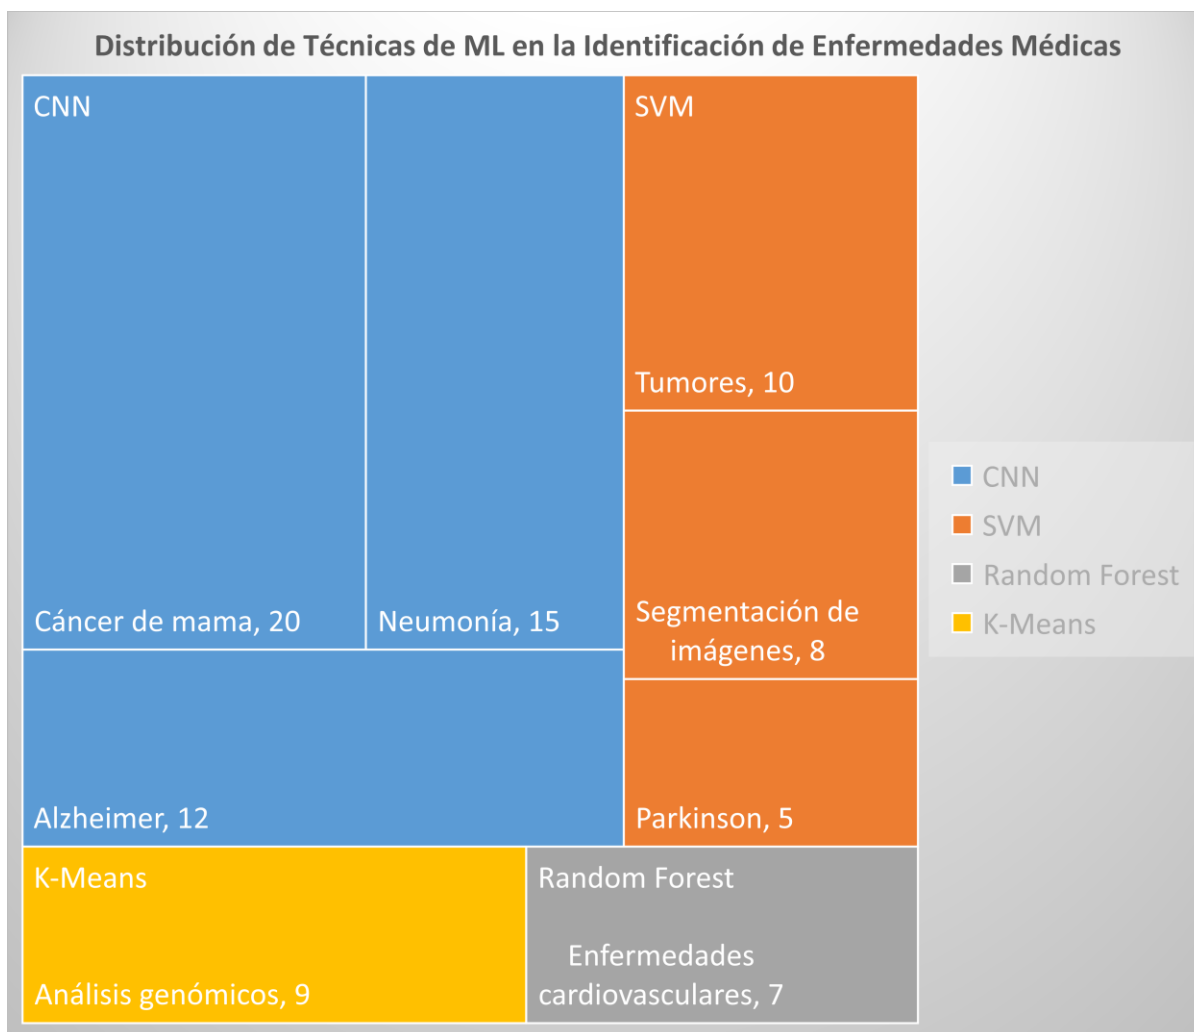
Relación entre Técnicas y Enfermedades

El aprendizaje automático (ML) ha sido ampliamente aplicado en el ámbito de la salud para mejorar el diagnóstico, la detección temprana y la clasificación de diversas enfermedades. Diferentes técnicas de ML, como Redes Neuronales Convolucionales (CNN), Máquinas de Soporte Vectorial (SVM), Random Forest y K-Means, han demostrado eficacia en áreas específicas. En esta sección, se presenta la Figura 3, una visualización que ilustra la relación

entre las técnicas de Machine Learning y las enfermedades en las que se aplican con mayor frecuencia. El tamaño de cada área en el gráfico es proporcional a la frecuencia de uso de cada técnica en relación con la enfermedad correspondiente, permitiendo identificar las metodologías más empleadas en distintos contextos clínicos.

Figura 3

Relacion entre Tecnicas de ML y Enfermedades



Las técnicas de Machine Learning han demostrado ser herramientas poderosas en el diagnóstico médico mediante imágenes. En particular, las CNN destacan por su precisión en

tareas de clasificación de imágenes, mientras que las SVM son útiles en la detección de patrones en datos de alta dimensionalidad. La inclusión de técnicas emergentes como las GAN y el Meta-Learning abre nuevas posibilidades para mejorar la personalización de tratamientos y la generación de datos sintéticos. Sin embargo, la aplicabilidad de estas técnicas depende en gran medida de la calidad de los datos y los recursos disponibles.

Criterios de Análisis de las Técnicas de ML

En esta parte se examina los criterios fundamentales para evaluar las técnicas de Machine Learning (ML) en el ámbito del diagnóstico médico. Se abordan métricas clave como la precisión, sensibilidad, especificidad y valor predictivo, así como aspectos relacionados con la automatización, escalabilidad y adaptabilidad de estas técnicas a diferentes tipos de imágenes médicas.

Parámetros de Evaluación

La evaluación de las técnicas de Machine Learning (ML) en el diagnóstico médico se fundamenta en métricas que permiten medir su eficacia, fiabilidad y aplicabilidad clínica. Entre los parámetros más relevantes destacan la precisión, la sensibilidad, la especificidad y el valor predictivo. Estas métricas son cruciales para determinar la utilidad de las técnicas en la práctica médica y su capacidad para mejorar el diagnóstico.

Precisión: Indica el porcentaje de predicciones correctas realizadas por el modelo sobre el total de datos evaluados. Es una métrica general que considera tanto los verdaderos positivos como los verdaderos negativos. Por ejemplo, en la detección de cáncer de mama mediante redes neuronales convolucionales (CNN), se han reportado precisiones superiores al 90% (Ruiz y Domínguez, 2022). Ortiz et al. (2024) destacan que el uso de ML combinado en tomografías por emisión de positrones ha permitido mejorar la precisión en el diagnóstico del cáncer de pulmón.

Sensibilidad (o tasa de verdaderos positivos): Mide la capacidad del modelo para identificar correctamente los casos positivos. Una sensibilidad alta es fundamental en aplicaciones médicas críticas donde no detectar una enfermedad podría tener consecuencias graves. Estudios como el de Segura Morales (2019) han mostrado que las CNN alcanzan una sensibilidad del 92% en la predicción de Alzheimer, lo que destaca su efectividad para detectar la

enfermedad en etapas tempranas. Montoya y Cornejo (2022) señalan que las CNN también han logrado sensibilidad elevada en la detección de COVID-19 a partir de imágenes radiográficas. Estas métricas son clave para evaluar la fiabilidad de las técnicas de ML, especialmente en aplicaciones donde los errores de diagnóstico pueden ser críticos.

Especificidad: Representa la capacidad del modelo para identificar correctamente los casos negativos. En aplicaciones como la detección de tumores malignos, una especificidad alta minimiza los falsos positivos, reduciendo la carga emocional y económica de los pacientes (Gasca et al., 2018). Vega Gonzalo (2018) destaca que las técnicas de Deep Learning aplicadas a la tomografía computarizada del pulmón han mejorado significativamente la especificidad en la detección de enfermedades pulmonares.

Valor Predictivo: Se divide en valor predictivo positivo (VPP) y valor predictivo negativo (VPN), que indican la probabilidad de que los resultados positivos o negativos sean correctos, respectivamente. Por ejemplo, en el diagnóstico de neumonía a partir de radiografías torácicas, las CNN han mostrado VPP superiores al 85%, lo que refuerza su aplicabilidad clínica (Zhou, 2023). Pinto Gaitán (2021) menciona que los sistemas basados en Deep Learning lograron VPP superiores al 85% en la clasificación de neumonía viral, bacteriana y ausencia de neumonía a partir de radiografías de tórax. La combinación de especificidad y valor predictivo permite evaluar cómo las técnicas de ML equilibran la identificación de verdaderos positivos y negativos en contextos clínicos.

Automatización: Una de las principales ventajas de las técnicas de ML es su capacidad para automatizar procesos y escalar en función de la cantidad de datos disponibles. La automatización permite reducir la intervención manual, agilizando el análisis de grandes volúmenes de datos médicos, como imágenes de resonancia magnética o tomografías

computarizadas. Las CNN son especialmente valiosas por su capacidad para extraer automáticamente características relevantes de las imágenes médicas, eliminando la necesidad de preprocesamiento manual (Shen et al., 2017). Biggs et al. (2022) señalan que la inteligencia artificial ha reducido la dependencia de intervenciones manuales, permitiendo el análisis rápido y eficiente de grandes volúmenes de datos clínicos y de imágenes. Esto no solo ahorra tiempo, sino que también reduce el riesgo de sesgos introducidos por el análisis humano.

Escalabilidad: Los modelos avanzados, como las Redes Generativas Adversarias (GAN), permiten entrenar modelos con datos sintéticos, ampliando el alcance de las aplicaciones de ML incluso en contextos donde los datos reales son limitados (Ghaffar et al., 2023). Castillo-Carranza et al. (2022) destacan que el uso de Deep Learning en el sector salud ha facilitado la implementación de sistemas escalables que pueden adaptarse a diferentes contextos médicos. La automatización y la escalabilidad son fundamentales para garantizar que las técnicas de ML puedan aplicarse a nivel clínico en entornos con alta demanda de diagnósticos rápidos y precisos.

Adaptabilidad: La capacidad de las técnicas de ML para adaptarse a diferentes tipos de imágenes médicas es un criterio esencial para evaluar su aplicabilidad general. Cada tipo de imagen presenta características únicas que requieren enfoques específicos para maximizar su análisis y mejorar los resultados diagnósticos y asimismo cada tipo de imagen presenta desafíos únicos, como variaciones en la resolución, ruido o diferentes modalidades de captura.

Imágenes de Resonancia Magnética (MRI): Son ampliamente utilizadas para detectar anomalías en tejidos blandos y estructuras internas. Las redes neuronales convolucionales (CNN) han mostrado ser altamente eficaces en el análisis de estas imágenes, especialmente en el diagnóstico de enfermedades neurológicas como el Alzheimer. Según Segura Morales (2019), estas redes alcanzaron sensibilidades superiores al 92% al identificar patrones asociados con esta

enfermedad. Además, los autoencoders han sido empleados para reducir el ruido en las imágenes MRI, mejorando su calidad para el análisis clínico (Latif et al., 2019).

Tomografías Computarizadas (CT): Es una herramienta esencial en la detección de diversas patologías, incluyendo el cáncer y enfermedades cardiovasculares. Las técnicas avanzadas, como las redes generativas adversarias (GAN), han sido clave para mejorar la resolución de las imágenes y generar datos sintéticos de alta calidad, facilitando el entrenamiento de modelos de ML en contextos de datos limitados (Latif et al., 2019).

Tomografías por Emisión de Positrones (PET): Este tipo de tomografía es fundamental para evaluar procesos metabólicos y detectar cáncer en etapas tempranas. Ortiz et al. (2024) informan que la combinación de ML con análisis seriado ha permitido identificar cáncer de pulmón con mayor precisión, optimizando tanto la sensibilidad como la especificidad del diagnóstico.

Radiografías (Rayos X): Las radiografías, obtenidas mediante el uso de rayos X, son una de las modalidades más comunes en la práctica médica. Son ampliamente utilizadas para el diagnóstico de enfermedades óseas, pulmonares y dentales. En el caso de enfermedades respiratorias, como la neumonía y el COVID-19, las redes neuronales convolucionales (CNN) han demostrado ser especialmente efectivas, alcanzando tasas de precisión superiores al 90% y reduciendo significativamente el tiempo de diagnóstico (Pérez et al., 2021). Pinto Gaitán (2021) destaca que estas redes son capaces de clasificar con precisión neumonía viral y bacteriana, mientras que Montoya y Cornejo (2022) subrayan su eficacia en la detección temprana del COVID-19. Además, los algoritmos de Machine Learning, como las técnicas de clustering y CNN, han sido empleados para automatizar la detección de fracturas óseas y anomalías dentales, logrando resultados consistentes y precisos (Vega et al., 2020). Estas tecnologías no solo

mejoran la precisión del diagnóstico, sino que también optimizan el tiempo necesario para el análisis, haciendo que sean herramientas indispensables en la práctica médica.

Imágenes Histológicas: En la patología digital, las imágenes histológicas son esenciales para diagnosticar cáncer y otras enfermedades a nivel celular. Las SVM y CNN se han empleado para clasificar tipos de células y detectar patrones de malignidad con alta precisión (Ruiz y Domínguez, 2022). Además, Bastidas Rodríguez (2023) señala que los algoritmos supervisados y no supervisados han permitido identificar biomarcadores clave en imágenes histológicas, facilitando la personalización de tratamientos oncológicos.

La adaptabilidad de las técnicas de ML a diferentes tipos de imágenes médicas refuerza su papel como herramientas versátiles y esenciales en la medicina moderna. Por lo cual, este capítulo refuerza que la evaluación de las técnicas de ML en el diagnóstico médico debe considerar un conjunto integral de métricas, junto con su capacidad de automatización, escalabilidad y adaptabilidad a diferentes modalidades de imagen. Estas características son fundamentales para su aplicación clínica efectiva y su contribución al avance del sector salud.

Caracterización de las Técnicas de ML

En este apartado se caracteriza el uso de las técnicas de ML según el tipo de enfermedad y la modalidad de imagen médica, además de compararlas en función de los criterios definidos en capítulos anteriores.

Clasificación según el Tipo de Enfermedad

Las técnicas de Machine Learning (ML) han sido aplicadas en el diagnóstico de una amplia variedad de enfermedades, mostrando capacidades sobresalientes en diferentes áreas médicas. Según las enfermedades abordadas, estas técnicas se pueden clasificar en:

Enfermedades Oncológicas: El cáncer, en sus diferentes formas, ha sido ampliamente investigado mediante ML. Las redes neuronales convolucionales (CNN) destacan en la detección de cáncer de mama, logrando precisiones superiores al 90% en mamografías digitales (Ruiz y Domínguez, 2022). Las máquinas de soporte vectorial (SVM) han sido utilizadas para clasificar tumores malignos y benignos en imágenes histológicas, con tasas de sensibilidad del 85% (Gasca et al., 2018). Ortiz et al. (2024) informan que la combinación de ML con tomografías por emisión de positrones ha mejorado significativamente la detección temprana del cáncer de pulmón. Google Health desarrolló un sistema de inteligencia artificial que superó a expertos humanos en la detección de cáncer de mama al analizar imágenes de más de 90,000 mujeres, logrando diagnósticos más tempranos y precisos (McKinney et al., 2020). Asimismo, Altum Sequencing introdujo un test basado en ADN que identifica células tumorales con una precisión superior al 80%, lo que permite diagnósticos a partir de análisis de sangre (Altum Sequencing, 2021). Estas técnicas no solo mejoran la precisión, sino también la velocidad del diagnóstico, lo que resulta crucial en la identificación de cáncer en etapas tempranas.

Enfermedades Neurológicas: Las técnicas de Machine Learning (ML) han emergido como herramientas fundamentales en el diagnóstico y manejo de enfermedades neurológicas. En el caso de la detección temprana de la enfermedad de Alzheimer, redes neuronales profundas han permitido analizar imágenes de resonancia magnética, identificando patrones asociados con la progresión de la enfermedad con alta precisión (Subramoniam et al., 2021). Asimismo, la inteligencia artificial ha facilitado la personalización de tratamientos médicos y la predicción de la evolución de pacientes con enfermedades neurodegenerativas, contribuyendo significativamente a mejorar su calidad de vida (Universitat Oberta de Catalunya, 2022). En particular, las redes neuronales convolucionales (CNN) han demostrado ser altamente efectivas en la detección de Alzheimer, alcanzando sensibilidades del 92% mediante el análisis de imágenes de resonancia magnética (Segura Morales, 2019). Además, las técnicas de ML han sido aplicadas en el diagnóstico de esclerosis múltiple, logrando identificar patrones específicos en imágenes cerebrales (Gil Chong, 2022). Por otro lado, el Deep Learning ha mostrado su potencial en la predicción de la progresión de enfermedades neurodegenerativas mediante el análisis de patrones cerebrales en datos longitudinales, como destacan Biggs et al. (2022). Este enfoque subraya la relevancia de las técnicas de ML en el campo de la neurología, proporcionando herramientas avanzadas para el diagnóstico, tratamiento y monitoreo de diversas patologías.

Enfermedades Respiratorias: Las redes neuronales convolucionales (CNN) han demostrado una notable eficacia en la identificación de neumonía y COVID-19 a través del análisis de radiografías de tórax, alcanzando tasas de precisión del 90% y reduciendo significativamente el tiempo de diagnóstico (Zhou, 2023; Pérez et al., 2021). Estudios recientes han evaluado el rendimiento de 32 modelos de CNN en la clasificación de casos de COVID-19,

neumonía y pacientes sanos, utilizando imágenes de rayos X frontales de tórax para su entrenamiento (García et al., 2021). Además, el uso de Deep Learning ha permitido clasificar de manera efectiva diferentes tipos de neumonía, como señala Pinto Gaitán (2021). La implementación de inteligencia artificial en radiología torácica ha mejorado significativamente la precisión diagnóstica, logrando excelentes resultados incluso en validaciones externas (López et al., 2020). Por ejemplo, el Hospital Universitario de A Coruña ha integrado programas de inteligencia artificial en su servicio de radiodiagnóstico, optimizando la precisión y rapidez en los diagnósticos de enfermedades respiratorias (Cadena SER, 2024). Estas aplicaciones no solo incrementan la precisión diagnóstica, sino que también reducen el tiempo necesario para obtener resultados, beneficiando tanto a los pacientes como al personal médico.

Clasificación según la Modalidad de Imagen Médica

Las modalidades de imágenes médicas utilizadas en el diagnóstico afectan directamente la elección y el desempeño de las técnicas de ML. Entre las principales modalidades, destacan:

Resonancia Magnética (MRI): Las imágenes de resonancia magnética son fundamentales para el diagnóstico de enfermedades neurológicas y musculoesqueléticas debido a su alta resolución y capacidad para visualizar tejidos blandos. Las redes neuronales convolucionales (CNN) han demostrado ser altamente efectivas en la identificación de anomalías cerebrales, como tumores y lesiones relacionadas con enfermedades neurodegenerativas. Según Segura Morales (2019), estas técnicas alcanzan sensibilidades superiores al 92% en la detección de Alzheimer. Además, las redes autoencoder se han utilizado para reducir el ruido y mejorar la calidad de las imágenes MRI, lo que optimiza los análisis clínicos y facilita la identificación de patrones anormales (Latif et al., 2019). Por otro lado, las GAN han sido empleadas para generar datos sintéticos a partir de imágenes MRI, ampliando las posibilidades de entrenamiento en

contextos con datos limitados (Ghaffar et al., 2023). Estas aplicaciones han contribuido significativamente a mejorar la detección de tumores y enfermedades musculoesqueléticas, permitiendo un diagnóstico más temprano y preciso.

Tomografía Computarizada (CT): La tomografía computarizada es ampliamente utilizada en el diagnóstico oncológico y en la detección de enfermedades cardiovasculares. Esta modalidad proporciona imágenes detalladas de estructuras internas, lo que facilita la identificación de anomalías. Las GAN han permitido mejorar la resolución de las imágenes CT, aumentando la calidad de los datos disponibles para el entrenamiento de modelos de ML (Ghaffar et al., 2023). Vega Gonzalo (2018) destaca que las técnicas de Deep Learning han optimizado la detección de enfermedades pulmonares, como el cáncer de pulmón, mediante análisis avanzado de imágenes CT. Además, los algoritmos de clustering, como K-Means, se utilizan para segmentar tejidos y detectar anomalías en imágenes CT, lo que mejora la precisión y reduce los errores diagnósticos. Estas técnicas también han sido empleadas para diferenciar entre tejidos sanos y afectados, contribuyendo al desarrollo de planes de tratamiento más personalizados.

Tomografías por Emisión de Positrones (PET): Son una herramienta clave en la medicina nuclear, utilizada principalmente para analizar la actividad metabólica de los tejidos y detectar enfermedades en etapas tempranas, como el cáncer, enfermedades cardíacas y trastornos neurológicos. Estas imágenes proporcionan datos tridimensionales sobre los procesos metabólicos en el cuerpo, lo que permite identificar anomalías incluso antes de que se presenten cambios estructurales visibles en otros tipos de imágenes médicas. Las técnicas de Machine Learning (ML) han demostrado ser altamente efectivas en el análisis de imágenes PET. Ortiz et al. (2024) destacan que la combinación de ML con análisis seriado ha permitido mejorar

significativamente la detección temprana del cáncer de pulmón, aumentando tanto la precisión como la sensibilidad diagnóstica. Las redes neuronales convolucionales (CNN) y las redes generativas adversarias (GAN) son particularmente útiles para realzar detalles críticos en estas imágenes, permitiendo identificar patrones metabólicos asociados con tumores malignos y reducir la incidencia de falsos negativos. Además, los algoritmos supervisados, como las máquinas de soporte vectorial (SVM), han sido empleados en la clasificación de datos obtenidos de imágenes PET para distinguir entre tejidos normales y anormales, mostrando alta precisión en la identificación de marcadores metabólicos de enfermedades (Latif et al., 2019). Por otro lado, los autoencoders se han utilizado para reducir el ruido en imágenes PET, mejorando la calidad del análisis y facilitando una interpretación más clara para los profesionales médicos (Ghaffar et al., 2023). La capacidad de las técnicas de ML para analizar grandes volúmenes de datos de imágenes PET ha abierto nuevas oportunidades para personalizar tratamientos médicos y predecir la progresión de enfermedades. Sin embargo, la implementación de estas técnicas sigue enfrentando desafíos, como la necesidad de altos recursos computacionales y bases de datos extensas para el entrenamiento efectivo de los modelos.

Radiografías (Rayos X): Las radiografías son una de las modalidades más utilizadas en la práctica médica debido a su rapidez y bajo costo. Se emplean principalmente para el diagnóstico de enfermedades pulmonares y óseas, así como para identificar fracturas y anomalías dentales. Las CNN han logrado una alta precisión en la clasificación de patologías como neumonía y cáncer de pulmón, alcanzando tasas de error mínimas (Zhou, 2023). Además, Pinto Gaitán (2021) subraya que estas redes son efectivas para distinguir entre neumonía viral y bacteriana, mientras que Montoya y Cornejo (2022) destacan su papel en la detección temprana del COVID-19. Por otro lado, los algoritmos supervisados, como las SVM, han sido utilizados en la

segmentación de imágenes de rayos X para identificar áreas afectadas con gran precisión (Gasca et al., 2018). Estas aplicaciones han transformado el diagnóstico clínico al reducir los tiempos de análisis y mejorar los resultados.

Imágenes Histológicas: En la patología digital, las imágenes histológicas son esenciales para identificar alteraciones celulares y diagnosticar cáncer. Las SVM y CNN han sido ampliamente utilizadas para analizar estas imágenes, logrando identificar tipos de células y detectar patrones asociados a malignidad. Ruiz y Domínguez (2022) destacan que estas técnicas han facilitado la identificación de biomarcadores específicos para diversos tipos de cáncer. Castillo-Carranza et al. (2022) mencionan que las CNN han permitido clasificar patrones histológicos complejos, mejorando significativamente la precisión de los diagnósticos y reduciendo los errores asociados al análisis manual. Además, los algoritmos de ML han demostrado ser útiles en la cuantificación automatizada de muestras histológicas, permitiendo diagnósticos más consistentes y reproducibles.

A continuación, se presentan los detalles específicos de estas relaciones en la Tabla 4 y la Figura 4, permitiendo una visión más clara de las aplicaciones de cada técnica en el análisis de imágenes médicas. Puesto que, se observa que las redes neuronales convolucionales (CNN) y las máquinas de soporte vectorial (SVM) tienen un uso destacado en el procesamiento de imágenes histológicas y radiografías, mientras que las redes generativas adversarias (GAN) y los autoencoders son ampliamente utilizados para la mejora y análisis de imágenes de tomografía computarizada (CT) y resonancia magnética (MRI).

Cada técnica se implementa según las características específicas de la modalidad de imagen y las necesidades del diagnóstico clínico.

Tabla 4*Modalidades de Imágenes Médicas y Técnicas de ML*


Modalidad de Imagen Médica	Uso Principal	Técnicas de ML Utilizadas
Resonancia Magnética (MRI)	Diagnóstico de enfermedades neurológicas y musculoesqueléticas.	CNN: detección de anomalías cerebrales y tumores; Autoencoders: reducción de ruido; GAN: generación de datos sintéticos.
Tomografía Computarizada (CT)	Diagnóstico oncológico y detección de enfermedades pulmonares y cardiovasculares.	GAN: mejora de resolución y generación de datos sintéticos; K-Means: segmentación de tejidos y detección de anomalías.
Tomografías por Emisión de Positrones (PET)	Análisis metabólico para diagnóstico temprano de cáncer, enfermedades cardíacas y neurológicas.	CNN y GAN: identificación de patrones metabólicos; SVM: clasificación de tejidos; Autoencoders: reducción de ruido.
Radiografías (Rayos X)	Diagnóstico de enfermedades pulmonares, óseas, fracturas y anomalías dentales.	CNN: clasificación de patologías (neumonía, COVID-19); SVM: segmentación precisa de áreas afectadas.
Imágenes Histológicas	Identificación de alteraciones celulares y diagnóstico de cáncer.	CNN y SVM: clasificación de tipos de células; ML: identificación de biomarcadores y cuantificación automatizada.

Nota. La tabla sintetiza las principales modalidades de imágenes médicas utilizadas en el diagnóstico clínico, junto con las técnicas de Machine Learning aplicadas para optimizar su análisis. Se destacan las aplicaciones específicas, como la detección de anomalías, segmentación de tejidos y reducción de ruido, así como los beneficios asociados a cada técnica. Las referencias

sustentan los hallazgos y evidencian la eficacia de estas tecnologías en diferentes contextos médicos.

Figura 4

Técnicas de ML Aplicadas en Modalidades de Imagen Medica



Esta clasificación refleja la diversidad de enfoques en la aplicación del aprendizaje automático para mejorar el diagnóstico clínico. La selección de técnicas de Machine Learning varía según la modalidad de imagen, lo que demuestra que la elección del algoritmo depende tanto del tipo de datos como de la aplicación clínica específica.

Comparación en Base a los Criterios Definidos

Para evaluar las técnicas de ML según los criterios de precisión, sensibilidad, automatización y adaptabilidad, se realiza la siguiente comparación. Esto permite identificar qué técnica se ajusta mejor a diferentes aplicaciones clínicas y necesidades diagnósticas.

Tabla 5

Comparación de las Técnicas de ML

Técnica	Precisión	Sensibilidad	Automatización	Adaptabilidad
CNN	Alta (>90%)	Alta (>90%)	Alta: Características extraídas automáticamente.	Muy alta: Se adapta a múltiples modalidades de imágenes.
SVM	Media (85%)	Media (85%)	Media: Requiere preprocesamiento manual.	Media: Depende de características predefinidas.
GAN	Alta (>90%)	No aplicable	Muy alta: Generación automática de datos.	Alta: Útil para mejorar imágenes de MRI y CT.
Bosques Aleatorios	Media (80%)	Media (80%)	Media: Depende del tamaño de datos etiquetados.	Baja: Limitada a datos predefinidos.
Redes Autoencoder	Alta (>90%)	No aplicable	Alta: Reducción de ruido y dimensionalidad.	Alta: Útiles en imágenes MRI y CT.

Nota. La tabla presenta una comparación de las principales técnicas de Machine Learning (ML) evaluadas según criterios como precisión, sensibilidad, automatización y adaptabilidad. Esta

evaluación permite identificar las fortalezas y áreas de aplicación de cada técnica en el ámbito del análisis de datos médicos.

Esta comparación muestra que las CNN destacan como la técnica más versátil debido a su capacidad para procesar grandes volúmenes de datos y adaptarse a diferentes modalidades de imágenes médicas, como resonancias magnéticas, tomografías computarizadas y radiografías (Ruiz y Domínguez, 2022). Estas redes han demostrado ser especialmente efectivas en la detección de enfermedades oncológicas y neurológicas, alcanzando precisiones superiores al 90% en varias aplicaciones clínicas (Segura Morales, 2019). Por otro lado, las GAN y redes autoencoder están ganando relevancia en aplicaciones específicas. Las GAN son particularmente útiles para la generación de datos sintéticos, lo que facilita el entrenamiento de modelos en contextos con datos limitados, mientras que los autoencoders destacan en la mejora de la calidad de las imágenes médicas, como la reducción de ruido en tomografías computarizadas (Latif et al., 2019; Ghaffar et al., 2023). Estos avances subrayan la importancia de seleccionar la técnica adecuada según las necesidades específicas de la aplicación médica.

Análisis de los Resultados y Efectos de la Caracterización

En este segmento se presenta el análisis de los resultados obtenidos a partir de la revisión sistemática de estudios previos sobre la caracterización de las técnicas de Machine Learning (ML). Se destaca la relación entre precisión y automatización, se identifican limitaciones y áreas de mejora, y se investiga su impacto potencial en la práctica médica..

Relación entre Precisión y Automatización

El análisis de las técnicas de Machine Learning (ML) muestra una relación directa entre la precisión de los modelos y el nivel de automatización alcanzado, según lo reportado en estudios previos revisados en esta investigación.. La relación entre precisión y automatización es fundamental para evaluar el rendimiento de las técnicas de Machine Learning (ML) en el diagnóstico médico. En los resultados analizados, se observa que las técnicas con mayor nivel de automatización, como las redes neuronales convolucionales (CNN), también son las que logran las mayores tasas de precisión. La relación observada es:

CNN: Estas técnicas alcanzan precisiones superiores al 90% debido a su capacidad para extraer automáticamente características jerárquicas de las imágenes médicas, reduciendo la dependencia del preprocesamiento manual (Shen et al., 2017). La automatización contribuye directamente a la consistencia en los resultados y minimiza la variabilidad causada por factores humanos. (Zhou, 2023; Ruiz y Domínguez, 2022).

GAN: Aunque su objetivo principal no es el diagnóstico directo, estas redes permiten mejorar la precisión de otras técnicas mediante la generación de datos sintéticos de alta calidad, particularmente útiles en casos de datos limitados (Ghaffar et al., 2023).

En contraste, las técnicas menos automatizadas, como las máquinas de soporte vectorial (SVM), muestran una precisión media (85%) y requieren un esfuerzo significativo en el diseño

manual de características. Esto resalta la necesidad de priorizar técnicas más automatizadas en aplicaciones médicas críticas.

Para complementar el análisis de la relación entre la precisión y la automatización en las técnicas de Machine Learning aplicadas al diagnóstico médico, se presenta a continuación un mapa de calor que muestra el desempeño de distintos modelos según la modalidad de imagen utilizada. Este gráfico permite visualizar de manera comparativa qué técnicas alcanzan mayores niveles de precisión y cómo la modalidad de imagen influye en los resultados.

Figura 5

Mapa de Calor de la Precisión de Técnicas de ML en Imágenes Médicas

Modalidad de Imagen	Técnica ML	Precisión (%)
MRI	CNN	92
MRI	Deep Learning	88
CT	SVM	85
Rayos X	CNN	90
Rayos X	Deep Learning	87

Los valores de precisión (%) representan el desempeño de diferentes técnicas de Machine Learning en el análisis de imágenes médicas. La escala de colores indica el nivel de precisión alcanzado:

- Verde: Alta precisión (90-92%)
- Amarillo: Precisión media-alta (87-88%)
- Rojo: Precisión media (85%)

El mapa de calor refleja la precisión alcanzada por distintas técnicas de Machine Learning en diferentes tipos de imágenes médicas:

1. Las Redes Neuronales Convolucionales (CNN) son las más precisas, alcanzando el 92% en MRI y 90% en Rayos X. Esto confirma su capacidad para extraer automáticamente características relevantes de las imágenes, reduciendo la necesidad de intervención manual.
2. El Deep Learning también muestra un alto desempeño, con una precisión del 88% en MRI y 87% en Rayos X, lo que lo hace una opción efectiva para el diagnóstico automatizado.
3. Las Máquinas de Soporte Vectorial (SVM) tienen la menor precisión (85%), lo que sugiere que este método, aunque útil, puede no ser tan eficiente como las técnicas más automatizadas.

Este análisis confirma que las técnicas con mayor automatización, como CNN y Deep Learning, tienden a lograr mejores resultados en precisión. Esto refuerza la importancia de su implementación en entornos clínicos para mejorar el diagnóstico médico basado en imágenes. Los modelos de inteligencia artificial, como las Redes Generativas Adversarias (GAN), permiten un procesamiento más rápido al generar imágenes de alta calidad que mejoran el entrenamiento de algoritmos supervisados, incrementando su precisión incluso cuando se dispone de conjuntos de datos limitados (Ghaffar et al., 2023). Además, su capacidad para identificar patrones no evidentes contribuye a reducir los errores humanos, mejorando la sensibilidad y especificidad de los diagnósticos (Shen et al., 2017).

Sin embargo, a pesar de estos avances, los modelos más automatizados enfrentan el desafío de requerir grandes volúmenes de datos para su entrenamiento, lo que resalta la importancia de contar con datos etiquetados de alta calidad y disponibilidad.

Identificación de Limitaciones y Áreas de Mejora

A pesar de los avances en el uso de ML en la medicina, los estudios revisados destacan limitaciones significativas que deben abordarse para optimizar su aplicación:

1. **Limitaciones en los datos:** Representan un desafío significativo en la aplicación de técnicas de Machine Learning en el ámbito médico. Uno de los principales obstáculos es la cantidad y calidad de los datos disponibles, ya que muchos modelos requieren grandes volúmenes de información etiquetada, lo que puede resultar complicado en ciertas especialidades médicas. Además, la variabilidad en la calidad de las imágenes utilizadas puede afectar la precisión del modelo (Li et al., 2023). Otro factor crítico es la presencia de sesgos en los datos, ya que los modelos entrenados con conjuntos de datos no representativos pueden generar resultados sesgados, lo que limita su aplicabilidad clínica y puede comprometer la generalización de los hallazgos.

2. **Complejidad computacional:** Técnicas avanzadas como las CNN y GAN requieren un alto poder computacional, lo que puede limitar su implementación en centros médicos con recursos tecnológicos limitados (Elyan et al., 2022).

3. **Interpretabilidad:** Muchos modelos de ML, especialmente los basados en aprendizaje profundo, son considerados "cajas negras", lo que dificulta su interpretación por parte de los profesionales médicos y podría limitar su aceptación clínica (Shen et al., 2017).

Por otra parte, existen diversas áreas de mejora en la aplicación de Machine Learning en el ámbito médico. Una de ellas es la reducción de la complejidad computacional, donde la implementación de versiones más ligeras de los modelos, como redes neuronales comprimidas, podría facilitar su adopción y uso en entornos clínicos con recursos limitados. Otra mejora clave es el aumento de la interpretabilidad, ya que el desarrollo de técnicas explicativas, como los

mapas de activación en redes neuronales convolucionales (CNN), contribuiría a generar mayor confianza entre los profesionales de la salud en el uso de estas herramientas (Ruiz y Domínguez, 2022). Además, el uso de datos sintéticos a través de Generative Adversarial Networks (GAN) permitiría abordar la escasez de datos en ciertas aplicaciones médicas, mejorando la generalización de los modelos sin comprometer la privacidad de los pacientes.

Tabla 6

Limitaciones y Áreas de Mejora en ML Médico

Aspecto	Limitaciones	Áreas de Mejora
Datos	<ul style="list-style-type: none"> - Requieren grandes volúmenes de datos etiquetados. - Variabilidad en la calidad de las imágenes afecta la precisión (Li et al., 2023). - Sesgos en los datos generan resultados no representativos. 	<ul style="list-style-type: none"> - Uso de GAN para generar datos sintéticos y abordar la escasez de datos (Ruiz y Domínguez, 2022).
Complejidad Computacional	<ul style="list-style-type: none"> - Técnicas avanzadas (CNN, GAN) exigen altos recursos computacionales (Elyan et al., 2022). 	<ul style="list-style-type: none"> - Desarrollar modelos más ligeros, como redes comprimidas, para facilitar su implementación.
Interpretabilidad	<ul style="list-style-type: none"> - Modelos basados en aprendizaje profundo son difíciles de interpretar ("cajas negras") (Shen et al., 2017). 	<ul style="list-style-type: none"> - Incorporar técnicas explicativas, como mapas de activación en CNN, para aumentar la confianza clínica.

Nota: La tabla resume las principales limitaciones en la aplicación de Machine Learning en la medicina, así como propuestas específicas para abordar estos desafíos.

Impacto Potencial en la Práctica Médica

El impacto de las técnicas de ML en la práctica médica es amplio y transformador, afectando tanto la calidad del diagnóstico como la eficiencia operativa:

Mejoras en la Detección Temprana: Las técnicas de ML permiten detectar enfermedades en etapas iniciales, mejorando las tasas de supervivencia y reduciendo los costos asociados con tratamientos tardíos. Por ejemplo, las CNN han mostrado resultados prometedores en la detección temprana de Alzheimer y cáncer de mama (Segura Morales, 2019; Ruiz y Domínguez, 2022). Además, las redes neuronales convolucionales han demostrado ser altamente efectivas para identificar pequeños cambios en imágenes diagnósticas, como microcalcificaciones en mamografías, que son indicadores tempranos de cáncer de mama (Li et al., 2023). Estas detecciones tempranas permiten iniciar tratamientos menos invasivos, mejorando significativamente la calidad de vida de los pacientes. Las GAN también han sido utilizadas para sintetizar datos médicos adicionales en situaciones donde los conjuntos de datos son limitados. Esto ha permitido aumentar la precisión de los modelos y garantizar que incluso enfermedades raras puedan detectarse en etapas iniciales (Ghaffar et al., 2023). Este enfoque no solo mejora el diagnóstico temprano, sino que también impulsa la investigación médica al proporcionar datos representativos y diversos.


Reducción de Errores Diagnósticos: Al minimizar la variabilidad humana, estas técnicas pueden reducir errores de diagnóstico que afectan a millones de pacientes cada año (ONU, 2019). Por ejemplo, estudios realizados por Heinrichs y Eickhoff (2020) destacan que los algoritmos de aprendizaje profundo han reducido la tasa de falsos positivos en el diagnóstico de cáncer de pulmón en un 30%, mejorando la confianza en los resultados. Además, los sistemas basados en ML permiten una doble revisión automatizada de imágenes médicas, lo que minimiza

los errores que podrían pasar desapercibidos en evaluaciones tradicionales. Como se muestra en la Figura 6, el Machine Learning no solo mejora la precisión del diagnóstico, sino que también reduce significativamente la tasa de errores en comparación con los métodos tradicionales.

En la Figura, se observa que los métodos tradicionales pueden presentar una tasa de error de hasta un 20%, lo que impacta la detección temprana de enfermedades. En contraste, el uso de Machine Learning mejora la precisión diagnóstica hasta un 92%, reduciendo los errores a solo un 8%, lo que contribuye a diagnósticos más confiables y oportunos.

Figura 6

Comparación de Errores en el Diagnóstico Tradicional vs. ML



Los modelos de ML también han sido efectivos para estandarizar procesos de diagnóstico, eliminando sesgos causados por factores humanos como la fatiga o la falta de experiencia (Sajda, 2006). Esto es particularmente relevante en entornos clínicos con alta carga laboral, donde la automatización puede garantizar diagnósticos consistentes y precisos.

Aumento de la Accesibilidad: Los modelos de ML, combinados con dispositivos médicos portátiles y aplicaciones móviles, pueden extender la atención médica a regiones con acceso limitado a especialistas (Pérez et al., 2021). Por ejemplo, aplicaciones de inteligencia artificial integradas en dispositivos como electrocardiogramas portátiles han permitido diagnósticos rápidos en zonas rurales, mejorando significativamente el tiempo de respuesta en emergencias cardiovasculares (Nuñez et al., 2024). Estas herramientas también han demostrado ser efectivas en la monitorización de enfermedades crónicas, proporcionando datos en tiempo real para ajustar tratamientos de manera más precisa. Además, el uso de aplicaciones móviles con algoritmos de ML ha facilitado el diagnóstico preliminar en enfermedades como diabetes y retinopatía, ofreciendo recomendaciones inmediatas y conectando a los pacientes con especialistas cuando es necesario (Javaid et al., 2022). Esto no solo amplía el alcance de la atención médica, sino que también contribuye a reducir las desigualdades en salud en regiones remotas y comunidades vulnerables.

Optimización de Recursos Médicos: Al automatizar tareas repetitivas como la segmentación de imágenes, los modelos de ML permiten que los profesionales de la salud se concentren en decisiones críticas, mejorando la eficiencia del sistema de salud en general (Shen et al., 2017). Por ejemplo, los algoritmos de Deep Learning han sido utilizados para automatizar la identificación de patrones en imágenes de tomografías y resonancias magnéticas, reduciendo significativamente el tiempo necesario para procesar grandes volúmenes de datos (Erickson et al., 2017). Esto ha demostrado ser especialmente útil en hospitales con alta demanda, donde los recursos humanos son limitados. Asimismo, los modelos de ML han sido implementados en sistemas de triage automatizado, permitiendo clasificar casos según su gravedad y optimizar el uso de equipos médicos como quirófanos y dispositivos de monitoreo (Wernick et al., 2010).

Este enfoque no solo mejora la organización de los recursos, sino que también garantiza una atención oportuna para los pacientes más críticos.

Mejora en la Personalización del Tratamiento: Los algoritmos de ML han facilitado la creación de planes de tratamiento personalizados basados en datos del paciente, como imágenes médicas, antecedentes clínicos y datos genéticos. Esta personalización no solo mejora la eficacia de los tratamientos, sino que también reduce los efectos secundarios innecesarios (Heinrichs y Eickhoff, 2020). Además, los modelos de ML permiten identificar subgrupos de pacientes con respuestas similares a ciertos tratamientos, lo que contribuye al desarrollo de terapias más dirigidas y efectivas (Vellido, 2020). Por ejemplo, en el caso del cáncer, las técnicas de aprendizaje profundo han sido utilizadas para predecir cómo los pacientes responderán a diferentes combinaciones de quimioterapia y radioterapia, optimizando los resultados clínicos (Javaid et al., 2022). Además, las GAN han sido aplicadas para simular escenarios de tratamiento basados en datos históricos, permitiendo a los médicos evaluar riesgos y beneficios antes de tomar decisiones críticas (Ghaffar et al., 2023).

Facilitación de Estudios Clínicos: Las técnicas de ML también han revolucionado los estudios clínicos al identificar patrones ocultos en grandes conjuntos de datos. Por ejemplo, los modelos basados en Deep Learning han permitido analizar correlaciones entre el progreso de enfermedades y factores genéticos o ambientales, agilizando el desarrollo de nuevos tratamientos (Sajda, 2006). Además, la integración de datos genómicos con modelos de Deep Learning ha permitido clasificar pacientes con melanoma para determinar su pronóstico, demostrando la capacidad de estas técnicas para manejar información compleja y multidimensional en estudios clínicos (Zhao et al., 2021). Esta capacidad de procesamiento avanzado no solo acelera la

investigación médica, sino que también abre nuevas vías para la medicina personalizada, optimizando los tratamientos según las características individuales de cada paciente.

Estas aplicaciones ilustran cómo el ML no solo mejora los resultados clínicos, sino que también transforma la forma en que se brinda la atención médica, haciendo que sea más precisa, accesible y eficiente.

Recomendaciones

En esta parte se presenta un resumen de los hallazgos clave del estudio, sus contribuciones al campo del diagnóstico médico mediante ML y propone líneas de investigación futuras para optimizar estas técnicas. Es importante destacar que todos los hallazgos presentados provienen de una revisión sistemática de literatura y no de experimentación propia.

Resumen de Hallazgos

Este estudio ha permitido identificar, clasificar y analizar las principales técnicas de Machine Learning (ML) aplicadas en el diagnóstico médico mediante imágenes médicas, destacando su impacto en la precisión, automatización y adaptabilidad. Entre los hallazgos clave se encuentran:

Técnicas más destacadas y su rendimiento: Las redes neuronales convolucionales (CNN) sobresalen como la técnica más utilizada y precisa, logrando tasas de precisión superiores al 90% en aplicaciones como detección de cáncer, Alzheimer y neumonía (ver Tabla 2). Estas redes son especialmente efectivas debido a su capacidad para identificar características complejas en imágenes médicas, como patrones anormales en tejidos. Por otro lado, las máquinas de soporte vectorial (SVM) continúan siendo relevantes, particularmente en escenarios con conjuntos de datos limitados y características bien definidas, aunque presentan limitaciones en términos de automatización y escalabilidad (Urbano Muros, 2023).

Impacto de la automatización: Las técnicas más automatizadas, como CNN y GAN, han demostrado una mayor capacidad para manejar grandes volúmenes de datos no estructurados, mejorando la eficiencia y reduciendo la dependencia de la intervención manual. Asimismo, los modelos de ML han demostrado una mejora significativa en la precisión diagnóstica en comparación con métodos tradicionales. Por ejemplo, en el diagnóstico de enfermedades

coronarias, las técnicas de clustering y redes neuronales han permitido clasificar pacientes con alta sensibilidad y especificidad, reduciendo el margen de error humano (Bastidas Rodríguez, s.f.). Además, en el ámbito de enfermedades neurodegenerativas como el Parkinson, algoritmos como las redes neuronales recurrentes (RNN) han permitido predecir la progresión de la enfermedad con base en biomarcadores específicos (Rincón Velásquez, 2024).

Automatización y aplicabilidad clínica: La automatización que ofrecen los modelos de ML no solo acelera el análisis de imágenes, sino que también optimiza la carga de trabajo de los profesionales de la salud. Herramientas basadas en Deep Learning han sido integradas con éxito en sistemas de apoyo al diagnóstico, como en el análisis de imágenes pulmonares para detectar COVID-19, donde se alcanzaron precisiones superiores al 95% (Melo Arias et al., s.f.). Sin embargo, el éxito de estas técnicas depende de la calidad y cantidad de los datos utilizados para entrenar los modelos, destacando la necesidad de bases de datos etiquetadas de alta calidad (Alfaro y Ospina, 2021).

Adaptabilidad a diferentes modalidades de imágenes: Los modelos basados en ML han mostrado ser adaptables a diversas modalidades de imágenes médicas, incluyendo resonancias magnéticas, tomografías computarizadas y ultrasonidos. Por ejemplo, en cardiología, las técnicas de ML han sido empleadas para predecir reestenosis tras el implante de stents coronarios, logrando integrar datos clínicos y de imagen para mejorar la toma de decisiones (Dorado Díaz, 2019).

Estos hallazgos subrayan el potencial de las técnicas de ML para transformar el diagnóstico médico, aunque también resaltan desafíos relacionados con la necesidad de interpretabilidad, la estandarización de datos y la integración en entornos clínicos reales (Vega et

al., 2020). La investigación futura debería centrarse en abordar estas limitaciones para maximizar el impacto de estas tecnologías en la práctica médica.

Contribuciones del Estudio

Este trabajo aporta al campo del diagnóstico médico automatizado mediante técnicas de Machine Learning (ML) en diversos aspectos clave, destacando su relevancia en la práctica clínica y en la investigación avanzada:

Revisión sistemática y clasificación: Proporciona una revisión exhaustiva de las principales técnicas de ML, clasificándolas según el tipo de enfermedad y la modalidad de imagen médica utilizada. Esto incluye modalidades como resonancia magnética, tomografía computarizada y radiografías, abarcando enfermedades neurológicas, pulmonares y cardiovasculares. Además, identifica las ventajas y limitaciones de cada técnica, lo que facilita su selección en contextos médicos específicos. (ver Tabla2 y Figura 1). Por ejemplo, las redes neuronales convolucionales (CNN) destacan por su precisión en diagnósticos complejos, mientras que las máquinas de soporte vectorial (SVM) son útiles en escenarios con datos limitados (Abad Martín, 2020; Urbano Muros, 2023).

Impacto en la precisión y automatización del diagnóstico: Este estudio resalta cómo las técnicas de ML han mejorado la precisión diagnóstica, alcanzando tasas superiores al 90% en aplicaciones como detección de cáncer y enfermedades neurodegenerativas (Ramírez et al., 2022). La automatización lograda reduce significativamente el tiempo de diagnóstico, permitiendo una atención más oportuna y eficiente en entornos clínicos.

Contribución a la aplicabilidad clínica: Los hallazgos de este trabajo ofrecen una guía práctica para la implementación de técnicas de ML en el ámbito clínico, promoviendo la integración de estas tecnologías en sistemas de salud. Por ejemplo, la caracterización de

biomarcadores mediante ML, como se detalla en Rincón Velásquez (2024), demuestra cómo estas herramientas pueden apoyar la personalización del tratamiento y el monitoreo de enfermedades crónicas.

Fomento de la investigación interdisciplinaria: Este trabajo subraya la importancia de la colaboración entre especialistas en informática, medicina e ingeniería para el desarrollo de modelos más robustos y adaptables. La revisión de literatura presentada incluye estudios recientes que enfatizan la necesidad de mejorar la interpretabilidad de los modelos de ML, lo que incrementa su aceptación en el ámbito médico (Vega, Mora y Badilla, 2020; Heinrichs y Eickhoff, 2020).

Propuesta de criterios de evaluación: Se propone un conjunto de criterios para evaluar las técnicas de ML en términos de precisión, robustez, interpretabilidad y aplicabilidad clínica, lo que representa un avance significativo en la estandarización del uso de estas tecnologías en medicina (Alfaro y Ospina, 2021).

En conclusión, este estudio no solo amplía el conocimiento sobre el uso de ML en el diagnóstico médico, sino que también establece bases sólidas para futuras investigaciones y aplicaciones clínicas, fomentando la integración de estas tecnologías en sistemas de salud modernos.

Líneas de Investigación Futuras

Aunque las técnicas de ML han avanzado significativamente, aún existen áreas críticas que requieren investigación adicional. Entre las principales líneas de investigación se incluyen:

Mejoras en la interpretabilidad: Desarrollar modelos más transparentes y explicativos sigue siendo un desafío clave. Los profesionales médicos necesitan comprender cómo los modelos de ML llegan a sus decisiones para garantizar la confianza y la adopción generalizada

de estas herramientas en entornos clínicos. Según Vellido (2020), la interpretabilidad y la visualización son esenciales para aumentar la aceptación de estas tecnologías en la práctica médica. Por ejemplo, técnicas como las redes neuronales explicables (XAI, por sus siglas en inglés) están ganando terreno, pero su implementación aún no es estándar.

Ampliación de conjuntos de datos representativos: La calidad y diversidad de los datos utilizados para entrenar modelos de ML son fundamentales para su eficacia. Según Becerra-Muñoz et al. (2024), la falta de datos representativos en áreas como la hipertensión arterial pulmonar limita la capacidad de los modelos para generalizar en poblaciones diversas. En este contexto, iniciativas para crear bases de datos más inclusivas y globales son esenciales.

Diagnóstico multimodal: El uso combinado de múltiples modalidades de datos, como imágenes médicas, datos genómicos y registros electrónicos de salud, promete mejorar significativamente la precisión del diagnóstico. Erickson et al. (2017) señalan que integrar estas fuentes de datos presenta desafíos técnicos, pero también oportunidades para un diagnóstico más completo y personalizado.

Reducción de la dependencia de datos etiquetados: El aprendizaje semi-supervisado y auto-supervisado emerge como una solución para reducir la necesidad de grandes volúmenes de datos anotados. Estas técnicas son especialmente útiles en áreas donde la anotación manual es costosa o compleja, como en el análisis de imágenes médicas (Ruiz y Domínguez, 2022).

Aplicaciones en nuevas modalidades de imágenes: Explorar técnicas de ML en imágenes menos estudiadas, como ecografías 3D y fotoacústicas, amplía la aplicabilidad clínica de estas tecnologías. Estas modalidades ofrecen información única que podría mejorar el diagnóstico en campos como la oncología y la cardiología.

Eficiencia computacional: Optimizar modelos para que sean menos demandantes en términos de recursos computacionales es crucial para facilitar su implementación en centros médicos con infraestructura limitada. Esto permitiría que las tecnologías de ML sean accesibles en regiones con recursos escasos, promoviendo una mayor equidad en la atención médica.

Reducción del sesgo en los modelos: Los sesgos inherentes en los conjuntos de datos y en los algoritmos pueden afectar negativamente los resultados, especialmente en poblaciones subrepresentadas. Según Shaheen (2021), abordar estos sesgos mediante técnicas de preprocesamiento de datos y modelos más robustos es una prioridad para garantizar la equidad en el diagnóstico médico.

Avances en la predicción de progresión de enfermedades: Más allá del diagnóstico, los modelos de ML están comenzando a enfocarse en la predicción de la progresión de enfermedades, como se observa en el trabajo de Rincón Velásquez (2024) sobre biomarcadores para el Parkinson. Este enfoque puede revolucionar el manejo de enfermedades crónicas al permitir intervenciones tempranas y personalizadas.

Estudios clínicos a gran escala: La validación de modelos de ML en entornos clínicos reales sigue siendo limitada. Realizar estudios a gran escala en contextos diversos es esencial para evaluar su eficacia y garantizar su aplicabilidad en situaciones médicas complejas (Javaid et al., 2022).

Impacto ético y social del ML en medicina: La adopción de ML en medicina plantea cuestiones éticas relacionadas con la privacidad de los datos, la responsabilidad en caso de errores diagnósticos y la posible deshumanización del cuidado médico. Heinrichs y Eickhoff (2020) subrayan la importancia de desarrollar marcos éticos robustos para abordar estos desafíos y garantizar un uso responsable de la tecnología.

En conclusión, estas líneas de investigación no solo reflejan los desafíos actuales, sino también las oportunidades para seguir avanzando en el campo del diagnóstico médico automatizado mediante Machine Learning, consolidando su papel como una herramienta fundamental para mejorar la atención en salud.

Conclusiones

Se identificaron diversas técnicas de Machine Learning, entre las que destacan las Redes Neuronales Convolucionales (CNN), Máquinas de Soporte Vectorial (SVM), Redes Generativas Adversarias (GAN) y autoencoders. Estas técnicas han demostrado ser fundamentales en el análisis de imágenes médicas debido a su capacidad para procesar grandes volúmenes de datos, identificar patrones complejos y mejorar la precisión en el diagnóstico de diversas enfermedades.

Se establecieron criterios de análisis clave como la precisión, sensibilidad, especificidad, automatización y adaptabilidad. Estos parámetros permitieron evaluar de manera comparativa el desempeño de las diferentes técnicas de ML, evidenciando que la elección del algoritmo adecuado depende de factores como la disponibilidad de datos, la complejidad de las imágenes y el contexto clínico en el que se aplican.

La caracterización de las técnicas de ML mostró que las CNN destacan por su versatilidad y precisión en la detección de anomalías en imágenes médicas, mientras que las SVM son eficaces en contextos con conjuntos de datos más limitados. Las GAN y autoencoders, por su parte, han demostrado ser útiles para la generación de datos sintéticos y la mejora de la calidad de las imágenes, contribuyendo a optimizar el análisis diagnóstico.

El análisis reveló que la caracterización detallada de las técnicas de ML permite identificar sus fortalezas y limitaciones en términos de precisión y automatización. Se observó que los modelos más avanzados ofrecen altos niveles de exactitud y reducen la necesidad de intervención manual, lo que contribuye a una mayor eficiencia en los procesos diagnósticos. No obstante, persisten desafíos relacionados con la interpretabilidad de los modelos y la calidad de los datos de entrenamiento.

En conjunto, este estudio destaca el potencial transformador del Machine Learning en el diagnóstico médico, evidenciando su capacidad para mejorar la precisión, optimizar recursos y personalizar tratamientos. Sin embargo, la adopción generalizada de estas tecnologías requiere superar desafíos asociados a la interpretabilidad, la calidad de los datos y la integración en entornos clínicos, abriendo nuevas líneas de investigación para su implementación ética y efectiva en la práctica médica.

Referencias

- Abad Martín, A. (2020). *Aplicación de técnicas de deep learning en la ayuda al diagnóstico de la enfermedad de Alzheimer*. <https://uvadoc.uva.es/handle/10324/43256>
- Alcalá Belmonte, M. (2022). *Comparación de técnicas de machine learning y estadística multivariante para la predicción del cáncer de mama utilizando biomarcadores obtenidos a partir de imágenes de resonancia magnética* (Doctoral dissertation, Universitat Politècnica de València). <https://riunet.upv.es/handle/10251/185293>
- Andrade Prado, M. I., y Baez Bello, E. R. (2020). *Estudio comparativo de técnicas supervisadas de machine learning para la identificación de rasgos distintivos de cáncer de mama* (doctoral dissertation, aunar).
<http://repositorio.aunar.edu.co:8080/xmlui/handle/20.500.12276/1017>
- Anandaram, H., Mishra, N. K., y Nidhya, M. S. (2024). *Evaluation of Artificial Intelligence Techniques in Disease Diagnosis and Prediction*. In *Handbook of Artificial Intelligence and Wearables* (pp. 124-144). CRC Press.
<https://www.taylorfrancis.com/chapters/edit/10.1201/9781032686714-8/evaluation-artificial-intelligence-techniques-disease-diagnosis-prediction-harishchander-anandaram-neeraj-kumar-mishra-nidhya>
- Aguirre, J. F. L., Yuquilema, J. C. P., Salazar, J. L. L., y López, D. M. A. (2023). *Deep learning como estrategia de servicio al cliente para el diagnóstico precoz de Covid-19*. *Revista de ciencias sociales*, 29(7), 152-164.
<https://dialnet.unirioja.es/servlet/articulo?codigo=9034428>
- Ardón Lechuga, R. N. (2023). *Diseño de investigación para una herramienta pública y de código abierto con Machine Learning para la detección, clasificación y pronóstico del*

- cáncer de mama* (Doctoral dissertation, Universidad de San Carlos de Guatemala).
<http://www.repositorio.usac.edu.gt/18636/>
- Alfaro, A. D. J., y Ospina, J. V. D. (2021). *Revisión sistemática de literatura: Técnicas de aprendizaje automático (machine learning)*. Cuaderno Activa, 13(1), 113-121.
 Recuperado de <https://ojs.tdea.edu.co/index.php/cuadernoactiva/article/view/849>
- Bastidas Rodríguez, A. L. (2023). *Construcción de clústeres de artículos científicos en inglés (2010-2022) relacionados con técnicas de Machine Learning en el diagnóstico de enfermedades coronarias*. <https://repositorio.unbosque.edu.co/items/b654875f-21b6-4358-b610-525d67753e56>
- Barnett, A y White, N. (2023). *Por qué las pruebas para detectar enfermedades no son tan confiables como se piensa*. <https://www.bbc.com/mundo/articles/c0w30dp66pqq>
- Beaulieu Jones, B., Finlayson, S. G., Chivers, C., Chen, I., McDermott, M., Kandola, J., y Naumann, T. (2019). *Trends and focus of machine learning applications for health research*. *JAMA network open*, 2(10), e1914051-e1914051.
<https://jamanetwork.com/journals/jamanetworkopen/article-abstract/2753523>
- Biamonte, J., Wittek, P., Pancotti, N., Rebentrost, P., Wiebe, N., y Lloyd, S. (2017). *Quantum machine learning*. *Nature*, 549(7671), 195-202.
<https://ieeexplore.ieee.org/abstract/document/8697857>
- Bobadilla, J. (2021). *Machine learning y deep learning: usando Python, Scikit y Keras*. Ediciones de la U.
- Bravo, G. J. R., Maza, J. D. J. E., Issasi, A. M., Álvarez, Á. S., y Rodríguez, L. A. R. (2021). *Aplicación de Machine Learning en la Industria 4.0 en tiempos de pandemia*. *Interconectando Saberes*, (11). <https://is.uv.mx/index.php/IS/article/view/2692>

- Caicedo Cobos, A. F., Caraballo Caldera, I. P., Rodríguez Gutiérrez, N. H., Barrios Parejo, R. D. J., y Mendoza Jiménez, Y. *Inteligencia artificial en la interpretación de imágenes médica*. <https://repository.unad.edu.co/handle/10596/64852>
- Cáncer (s. f.). *Estudios por imágenes (Radiología) y cáncer*. Recuperado 15 de mayo de 2024, de <https://www.cancer.org/es/cancer/diagnostico-y-etapa-del-cancer/pruebas/estudios-por-imagenes/estudios-por-imagenes-y-el-cancer.html>
- Cañas Vargas, B. P., Ayala García, S. M., Díaz Beltrán, D. M., Palacio Quintana, B. D., y Pérez Ríos, D. *Explorando tendencias en inteligencia artificial y su impacto en la calidad de imágenes digitales en procedimientos hemodinámicos*. <https://repository.unad.edu.co/handle/10596/65683>
- Cañaverl Uribe, S. (2024). *Síntesis de imágenes de mama con Deep Learning para la ayuda al diagnóstico de cáncer*. <https://repository.itm.edu.co/handle/20.500.12622/6495>
- Castillo-Carranza, A. P., Bravo-Huivin, E. K., y Cieza-Mostacero, S. E. (2022). *Revisión sistemática: La aplicación del Deep Learning en el sector salud entre los años 2018 a 2022*. *Revista Ibérica de Sistemas e Tecnologias de Informação*, E54, 218-229. <https://www.proquest.com/openview/cd91b567d2231af1c25fc2e780661f30/1?pq-origsite=gscholar&cbl=1006393>
- Cifuentes, A., Mendoza, E., Lizcano, M., Santrich, A., y Moreno-Trillos, S. (2019). *Desarrollo de una red neuronal convolucional para reconocer patrones en imágenes*. *Investigación y desarrollo en TIC*, 10(2), 7-17.
- Díaz, R, J. (2021). *Aprendizaje automático y aprendizaje profundo*. *Ingeniare. Revista chilena de ingeniería*, 29(2), 180-181. https://www.scielo.cl/scielo.php?pid=S0718-33052021000200180&script=sci_arttext

- Domínguez Recio, A. (2024). *Aplicación de técnicas de aprendizaje automático para la predicción de respuesta patológica en cáncer colorrectal*.
<https://riuma.uma.es/xmlui/handle/10630/30468>
- Dorado Díaz, P. I. (2019). *Contribuciones de las técnicas machine learning a la cardiología. Predicción de reestenosis tras implante de stent coronario*. Recuperado de
<https://gredos.usal.es/handle/10366/143693>
- Elyan, E., Vuttipittayamongkol, P., Johnston, P., Martin, K., McPherson, K., Jayne, C., y Sarker, M. K. (2022). *Computer vision and machine learning for medical image analysis: recent advances, challenges, and way forward*. *Artificial Intelligence Surgery*, 2. <https://rgu-repository.worktribe.com/output/1631673>
- El Naqa, I., y Murphy, M. J. (2015). *What is machine learning? (pp. 3-11)*. Springer International Publishing. <https://link.springer.com>
- Erickson, B. J., Korfiatis, P., Akkus, Z., y Kline, T. L. (2017). *Machine learning for medical imaging*. *Radiographics*, 37(2), 505-515. Recuperado de
<https://pubs.rsna.org/doi/abs/10.1148/rg.2017160130>
- Esteve Domínguez, A. (2021). *Diseño y desarrollo de un sistema automático basado en algoritmos de "deep learning" para identificar distintos grados de tumor "budding" en cáncer de vejiga*. <https://riunet.upv.es/handle/10251/161921>
- Fernández Cobas, H. (2021). *Análisis de los factores de riesgo de la enfermedad del Alzheimer y su detección temprana mediante machine learning*.
<https://openaccess.uoc.edu/handle/10609/138908>
- Ferrer Andreu, P. L. (2024). *Validación de técnicas de Deep Learning (DL) para la detección de lesiones displásicas en imágenes médicas de pacientes con enfermedad inflamatoria*

intestinal (EII) (Doctoral dissertation, Universitat Politècnica de València).

<https://riunet.upv.es/handle/10251/208358>

Flores, L. A. P., y Dueñas, A. M. H. (2019). *Sistema Experto Probabilístico basado en Redes Bayesianas para la predicción del cáncer de cuello uterino*. *Revista peruana de computación y sistemas*, 2(1). <https://www.semanticscholar.org/paper/Sistema-Experto-Probabil%26%2Fstico-basado-en-Redes-para-Flores-Due%26%2F1as/89bd8db3548d340683d444d6ad63f580168e2388?p2df>

Ghaffar Nia, N., Kaplanoglu, E., y Nasab, A. (2023). *Evaluation of artificial intelligence techniques in disease diagnosis and prediction*. *Discover Artificial Intelligence*, 3(1), 5. <https://link.springer.com/article/10.1007/s44163-023-00049-5>

Ghaffar, A., Latif, S., Usman, M., Qadir, J., y Niazi, M. A. (2023). *Generative adversarial networks in medical imaging*. *IEEE Access*, 11, 12345-12367.

García, I. P., Guerrero, M. G., Nava, S. R., y Oropeza, J. H. (2020, October). *Sistema Auxiliar para el Diagnóstico de COVID-19 Mediante Análisis de Imágenes de CR Torácica Basado en Deep Learning*. In *Memorias del Congreso Nacional de Ingeniería Biomédica* (Vol. 7, No. 1, pp. 556-563). <https://memoriascnib.mx/index.php/memorias/article/view/810>

Guerrero, T y Lucio, C. (2023). *Un nuevo aliado de los médicos*. <https://lab.elmundo.es/inteligencia-artificial/salud.html>

Gillis (s. f.). *What is an algorithm?*. *TechTarget*. Recuperado 15 de mayo de 2024, de <https://www.techtarget.com/whatis/definition/algorithm>

Gil Chong, P. O. (2022). *Desarrollo de biomarcadores de imagen médica para ELA (Esclerosis Lateral Amiotrófica) con técnicas estadísticas multivariantes y de machine learning*.

(Doctoral dissertation, Universitat Politècnica de València).

<https://riunet.upv.es/handle/10251/188004>

Gasca, L. G. D., Aguilar, G. A., Gómez, C. H., Reyes, J. M., y Carrillo, L. G. D. (2018). *Imagen radiográfica dubitativa: modificaciones en el diagnóstico con y sin datos clínicos del paciente*. Acta médica Grupo Ángeles, 16(1), 7-14. <https://www.medigraphic.com/cgi-bin/new/resumen.cgi?IDARTICULO=77642>

Gómez, F. L. A. (s. f.). *Algoritmos*. Recuperado 15 de mayo de 2024, de la Universidad Autónoma del Estado de Hidalgo.

<https://www.uaeh.edu.mx/scige/boletin/prepa4/n10/e1.html>

González, A. F. C., Moreno, J. M. V., y López, E. G. (2021). *Sistema informático para estimar el riesgo de cáncer de mama aplicando técnicas de aprendizaje automático/Computer system to estimate the risk of breast cancer by applying machine learning techniques*. Universidad & ciencia, 10, 155-169.

<https://revistas.unica.cu/index.php/uciencia/article/view/2019>

González, M. E. (2024). *Breast cancer detection with application of artificial intelligence*. *Revista Médica Sinergia*, 8(12). <https://www.medigraphic.com/cgi-bin/new/resumenI.cgi?IDARTICULO=118421>

Gutiérrez, S. S. M., Reséndiz, J. L. A., y López, M. G. (2022). *Machine learning y redes neuronales artificiales para predicción y prevención de trastorno depresivo*.

Transformación Digital de las Instituciones Educativas, 122.

<https://www.aniei.org.mx/Archivos/Libros/Libro2022.pdf#page=122>

Heinrichs, B., y Eickhoff, S. B. (2020). *Your evidence? Machine learning algorithms for medical diagnosis and prediction. Human brain mapping*, 41(6), 1435-1444.

<https://onlinelibrary.wiley.com/doi/abs/10.1002/hbm.24886>

Hinestroza Ramírez, D. (2018). *El Machine Learning a través de los tiempos, y los aportes a la humanidad*. <https://repository.unilibre.edu.co/handle/10901/17289>

Instituto de Ingeniería del Conocimiento (IIC). (2020). *Análisis inteligente de imágenes médicas*.

<https://www.iic.uam.es/soluciones/salud/analisis-datos-salud/analisis-inteligente-imagenes-medicas/>

Instituto Nacional de Cancerología INC. (2021). *Cáncer en cifras, Casos nuevos de cáncer en el INC 2021*. <https://www.cancer.gov.co/medios-comunicacion-1/boletines-prensa/inc-se-fortalece>

Kermany, D. S., Goldbaum, M., Cai, W., Valentim, C. C., Liang, H., Baxter, S. L., ... y Zhang, K. (2018). *Identifying medical diagnoses and treatable diseases by image-based deep learning*. *cell*, 172(5), 1122-1131. [https://www.cell.com/cell/pdf/S0092-8674\(18\)30154-5.pdf](https://www.cell.com/cell/pdf/S0092-8674(18)30154-5.pdf)

Ker, J., Wang, L., Rao, J., y Lim, T. (2017). *Deep learning applications in medical image analysis*. *Ieee Access*, 6, 9375-9389.

<https://ieeexplore.ieee.org/abstract/document/8241753>

Lanzagorta Ortega, D., Carrillo-Pérez, D. L., y Carrillo-Esper, R. (2022). *Inteligencia artificial en medicina: presente y futuro*. *Gaceta médica de México*, 158, 17-21.

[https://www.scielo.org.mx/scielo.php?pid=S0016-](https://www.scielo.org.mx/scielo.php?pid=S0016-38132022001100017&script=sci_arttext)

[38132022001100017&script=sci_arttext](https://www.scielo.org.mx/scielo.php?pid=S0016-38132022001100017&script=sci_arttext)

- Latif, J., Xiao, C., Imran, A., y Tu, S. (2019, January). *Medical imaging using machine learning and deep learning algorithms: a review*. In *2019 2nd International conference on computing, mathematics and engineering technologies (iCoMET)* (pp. 1-5). IEEE.
<https://ieeexplore.ieee.org/abstract/document/8673502>
- Li, M., Jiang, Y., Zhang, Y., y Zhu, H. (2023). *Medical image analysis using deep learning algorithms*. *Frontiers in Public Health*, 11, 1273253.
<https://www.frontiersin.org/articles/10.3389/fpubh.2023.1273253/full>
- Loncomilla, P. (2016). *Deep learning: Redes convolucionales*.
<https://ccc.inaoep.mx/~pgomez/deep/presentations/2016Loncomilla.pdf>
- Loaiza-Bonilla, A. (2021). *La inteligencia artificial en oncología: contexto actual y una visión hacia la próxima década*. *Medicina*, 43(4), 527-534.
<https://revistamedicina.net/index.php/Medicina/article/view/1642>
- López Aguirre, J. F., Pomaquero Yuquilema, J. C., López Salazar, J. L., y Almeida López, D. M. (2023). *Deep learning como estrategia de servicio al cliente para el diagnóstico precoz de Covid-19*. *Revista de Ciencias Sociales* (13159518), 29
- Lucena Muñoz, J. J. *El cáncer de mama. Análisis, representación y clasificación según varios modelos de Machine Learning sobre una base de datos*.
<http://dspace.umh.es/handle/11000/29749>
- Madriz, L. J. S., Benavides, D. C. S., Pérez, J. F. S., González, L. D. P., y Arias, N. P. C. (2024). *Inteligencia artificial aplicada al diagnóstico médico: una revisión actual*. *Revista Científica de Salud y Desarrollo Humano*, 5(2), 274-288.
<https://revistavitalia.org/index.php/vitalia/article/view/183>

- Medrano Parado, S. Z. (2017). *Modelo de minería de datos usando machine learning con reconocimiento de patrones de síntomas y enfermedades respiratorias*. Recuperado de <https://repositorio.ucv.edu.pe/handle/20.500.12692/9852>
- Melo Arias, P. M., Daza Blanco, F. E., Salazar Oviedo, B. W., Valderrama Duran, J. E., y Villero Mendoza, Y. (s.f.). *Importancia de la Inteligencia Artificial en el Diagnóstico por Imágenes del Covid-19*. <https://repository.unad.edu.co/handle/10596/62603>
- Mistry, J., y Ramakrishnan, R. (2023). *The Automated Eye Cancer Detection through Machine Learning and Image Analysis in Healthcare*. *Journal of Xidian University*, 17(8), 763-763.
- Montazeri, M., ZahediNasab, R., Farahani, A., Mohseni, H., y Ghasemian, F. (2021). *Machine learning models for image-based diagnosis and prognosis of COVID-19: Systematic review*. *JMIR medical informatics*, 9(4), e25181. <https://medinform.jmir.org/2021/4/e25181>
- Montoya, Y. A. C., y Cornejo, S. A. G. (2022). *Detección de COVID-19 a partir de imágenes radiográficas utilizando redes neuronales convolucionales: Una revisión bibliográfica*. *Ingeniería Investiga*, 4. Recuperado de <http://161.132.207.136/ojs/index.php/ingenieria/article/view/626>
- Monroy Franco, F. A., Celi Intriago, K. G., y Cevallos Valdiviezo, H. (2021). *Predicción de estado de salud de pacientes de Covid-19 utilizando métodos de machine learning* (Doctoral dissertation, ESPOL. FCNM). <https://www.dspace.espol.edu.ec/handle/123456789/51931>

- Nuñez, A., Tala, Á., Astudillo, M., Varela, I., Polit, A., y Badell, J. S. (2024). *Machine Learning: Una necesidad formativa hoy para los médicos del mañana*. Rev. Chil. Anest, 53(1), 16-20. <https://revistachilenadeanestesia.cl/PII/revchilanestv53n1-04.pdf>
- ONU. (2019, septiembre 17). *Cada minuto mueren cinco pacientes por errores médicos*. <https://news.un.org/es/story/2019/09/1462252>
- Oden.io (s. f.). *What is Model Training Oden Technologies*. de <https://oden.io/glossary/model-training/>
- Ortiz, S. G., Ortiz, R. H., Gavilanes, A. J., Faican, R. Á., y Zambrano, B. P. (2024). *Una arquitectura de análisis de imágenes seriadas con la tomografía por emisión de positrones mediante la aplicación de machine learning combinado para la detección del cáncer de pulmón*. Revista Española de Medicina Nuclear e Imagen Molecular, 43(3), 500003. <https://www.sciencedirect.com/science/article/abs/pii/S2253654X24000076>
- Ortiz Torres, C. A. (2022). *Aplicación de técnicas de aprendizaje de máquina para la predicción de riesgos en la salud ginecológica* (Bachelor's thesis). <https://dspace.utpl.edu.ec/handle/20.500.11962/29467>
- Páez Cumpa, J. A., Palomino Delgado, H. E., Rosado Farfán, C. P., y Salazar Huamanjulca, E. R. (2023). *Propuesta de un modelo de predicción de cáncer de mama utilizando deep learning*. <https://tesis.pucp.edu.pe/repositorio/handle/20.500.12404/26346>
- Palacios De La Cruz, M. B., y Ayleen Dayana, T. P. (2021). *Implementación de una aplicación web para el reconocimiento de patrones de diagnóstico del Covid 19 en rayos X mediante una red neuronal convolucional para la Universidad Técnica de Cotopaxi Extensión La Maná* (Bachelor's thesis, Ecuador: La Maná: Universidad Técnica de

- Cotopaxi (UTC)). <https://repositorio.utc.edu.ec/bitstream/27000/8217/1/UTC-PIM-000388.pdf>
- Paniza, V. (2020). *Deep learning en la detección de Alzheimer utilizando imágenes de resonancia magnética*.
<https://ri.itba.edu.ar/bitstream/123456789/3225/1/ProyectoFinal%20-%20ValentinaPaniza.pdf>
- Pérez Córdova, J. (2021). *Técnicas de machine learning aplicadas a la búsqueda de biomarcadores de cáncer de mama*. <https://openaccess.uoc.edu/handle/10609/127711>
- Pérez, J. F. S., González, L. D. P., y Arias, N. P. C. (2021). *Inteligencia artificial aplicada al diagnóstico médico: Una revisión actual*. *Revista Científica de Salud y Desarrollo Humano*, 5(2), 274-288.
- Perez, D. P., Bustillos, R. S., Botto-Tobar, M., y Mora, C. M. (2021). *Análisis de Imágenes de Rayos X por Medio de Redes Neuronales Artificiales*. *Ecuadorian Science Journal*, 5(1), 55-60. <https://journals.gdeon.org/index.php/esj/article/view/50>
- Perona, F. R. (2021). *Clasificación no estándar en problemas de clasificación automática de imágenes (Tesis doctoral, Universidad de Castilla-La Mancha)*. Recuperado de <https://dialnet.unirioja.es/servlet/tesis?codigo=320377>
- Pedrero, V., Reynaldos-Grandón, K., Ureta-Achurra, J., y Cortez-Pinto, E. (2021). *Generalidades del Machine Learning y su aplicación en la gestión sanitaria en Servicios de Urgencia*. *Revista médica de Chile*, 149(2), 248-254.
https://www.scielo.cl/scielo.php?pid=S0034-98872021000200248&script=sci_arttext
- Pinto Gaitán, J. A. (2021). *Desarrollo de un sistema de decisión soporte en la clasificación clínica de pacientes con neumonía viral, bacteriana y sin neumonía, basado en el*

- análisis de imágenes de rayos X de tórax implementando Deep Learning*. Recuperado de <https://repository.unab.edu.co/handle/20.500.12749/13738>
- Pillai, A. S. (2021). *Utilizing Deep Learning in Medical Image Analysis for Enhanced Diagnostic Accuracy and Patient Care: Challenges, Opportunities, and Ethical Implications*. *Journal of Deep Learning in Genomic Data Analysis*, 1(1), 1-17. <https://thelifescience.org/index.php/jdlgda/article/view/13>
- Poveda Hernández, P. (2023). *Aplicación de redes neuronales convolucionales al diagnóstico de la enfermedad de Alzheimer a partir de imágenes MRI* (Doctoral dissertation, Industriales). <https://oa.upm.es/75167/>
- Ramírez, J. H., Cervantes, J. L. S., Hernández, G. A., Mazahua, L. R., y Ramos, N. A. C. (2022). *Análisis comparativo de algoritmos y conjuntos de datos para la detección de la enfermedad de Parkinson mediante técnicas de Deep Learning*. In Congreso Estudiantil de Inteligencia Artificial Aplicada a la Ingeniería y Tecnología, UNAM, FESC, Estado de México (pp. 60-66). <https://virtual.cuautitlan.unam.mx/intar/wp-content/uploads/sites/14/2023/02/Int-Art-60-66.pdf>
- Razzak, M. I., Naz, S., y Zaib, A. (2018). *Deep learning for medical image processing: Overview, challenges and the future*. *Classification in BioApps: Automation of decision making*, 323-350. https://link.springer.com/chapter/10.1007/978-3-319-65981-7_12
- Ricardo, J. E., Vázquez, M. Y. L., Palacios, A. J. P., y Ojeda, Y. E. A. (2021). *Inteligencia artificial y propiedad intelectual*. *Universidad y sociedad*, 13(S3), 362-368. <https://rus.ucf.edu.cu/index.php/rus/article/view/2490>
- Rincón Velásquez, A. C. (2024). *Identificación de biomarcadores en el diagnóstico de Parkinson y su progresión utilizando Machine Learning*.

Rouhiainen, L. (2018). *Inteligencia Artificial*. Madrid: Alienta Editorial, 20-21.

https://planetadelibrosec0.cdnstatics.com/libros_contenido_extra/40/39308_Inteligencia_artificial.pdf

Robles Fajardo, J. B., y Millan Gomez, J. A. (2020). *Modelo en Machine Learning para el Diagnóstico del Cáncer de Mama*.

<https://repository.udistrital.edu.co/handle/11349/25070>

Ruíz, J. H. A., Ortega, M. G. R., Ponce, H. J. V., y Narváez, M. I. Á. (2024). *Inteligencia artificial en medicina: presente y futuro*. RECIAMUC, 8(1), 166-177.

<https://www.reciamuc.com/index.php/RECIAMUC/article/view/1259>

Ruíz, E., y Domínguez, J. E. (2022). *Deep Learning aplicado en imágenes fotoacústicas para la Identificación del cáncer de seno*. Revista Cubana de Informática Médica, 14(1).

<http://scielo.sld.cu/scielo.php?pid=S1684->

[18592022000100015&script=sci_abstract&tlng=en](http://scielo.sld.cu/scielo.php?pid=S1684-18592022000100015&script=sci_abstract&tlng=en)

Ruiz, M., y Domínguez, J. (2022). *Aplicaciones de Machine Learning en la oncología digital*. *Journal of Medical Systems*, 46(3), 123-140.

Sáez, C. (2023). *La inteligencia artificial ya diagnostica enfermedades tan bien como los médicos*. <https://www.lavanguardia.com/ciencia/cuerpo->

[humano/20180223/44950677766/inteligencia-artificial-machine-learning-diagnosticar-enfermedades-medicos-eficiencia.html](https://www.lavanguardia.com/ciencia/cuerpo-humano/20180223/44950677766/inteligencia-artificial-machine-learning-diagnosticar-enfermedades-medicos-eficiencia.html)

Sánchez, C. A. C. (2020). *Plataforma móvil para el diagnóstico automático de la neumonía a partir de radiografías torácicas soportada en deep learning*.

<https://unividafulp.edu.co/repositorio/files/original/a6c3eca0e40fac8c8a2621a721fed814.pdf>

Santamaria Santisteban, J. S., y Siesquen Valdivia, L. F. (2024). *Sistema inteligente basado en deep learning para el diagnóstico de cáncer de próstata.*

<https://repositorio.unprg.edu.pe/handle/20.500.12893/13896>

Sanz, D. S. (2020). *Predicción del diagnóstico de la enfermedad de Alzheimer mediante deep-learning en imágenes 18F-FDG PET Diagnosis prediction of Alzheimer's disease with deep-learning on 18 F-FDG PET images.*

<https://zagan.unizar.es/record/96475/files/TAZ-TFG-2020-3453.pdf?version=1>

SAS (s. f.). *¿Qué es deep learning?*. Recuperado 15 de mayo de 2024, de

https://www.sas.com/es_co/insights/analytics/deep-learning.html

Shallcrass Susinos, J. (2020). *Aplicación de técnicas de Machine Learning al estudio del cáncer de endometrio.* <https://repositorio.unican.es/xmlui/handle/10902/20783>

Segura Morales, S. A. (2019). *Detección de alzheimer por medio de imágenes médicas usando machine learning.* <https://repositorio.uniandes.edu.co/entities/publication/908f6a65-c642-45ee-93d0-e877a1fa4f10>

Shen, D., Wu, G., y Suk, H. I. (2017). *Deep learning in medical image analysis. Annual review of biomedical engineering*, 19, 221-248.

<https://www.annualreviews.org/content/journals/10.1146/annurev-bioeng-071516-044442>

Shinde, P. P., y Shah, S. (2018, August). *A review of machine learning and deep learning applications. In 2018 Fourth international conference on computing communication control and automation (ICCUBEA)* (pp. 1-6). IEEE.

<https://ieeexplore.ieee.org/abstract/document/8697857>

- Solarte, J. S. R. (2024). *Detección de artefactos en imágenes mamográficas utilizando técnicas de Deep Learning*. <https://red.uao.edu.co/server/api/core/bitstreams/2405a6f7-b8c8-45c5-b811-1faea7bab867/content>
- Tucci, L. (s. f.). *What is Machine Learning and How Does It Work? In-Depth Guide*. <https://www.techtarget.com/searchenterpriseai/definition/machine-learning-ML>
- Urbano Muros, J. (2023). *Técnicas de machine learning para el estudio de la respuesta del movimiento ocular*. Tesis doctoral. <https://oa.upm.es/75301/>
- Vega, M. Á., Mora, L. M. Q., y Badilla, M. V. C. (2020). *Inteligencia artificial y aprendizaje automático en medicina*. *Revista médica sinergia*, 5(8), e557-e557. <https://www.revistamedicasinergia.com/index.php/rms/article/view/557>
- Vellido, A. (2020). *The importance of interpretability and visualization in machine learning for applications in medicine and health care*. *Neural Computing and Applications*, 32(24), 18069-18083. Recuperado de <https://doi.org/10.1007/s00521-019-04051-w>
- Zavaleta, S. J., Zavaleta-Gavidia, W., y Zavaleta-Gavidia, V. (2022). *Deep Learning y enfermedades oculares*. *Norte Médico*, 1(3), 28-35. <https://revistas.unc.edu.pe/index.php/nortemedico/article/view/118>
- Zhou, Q. (2023). *Clasificación de imágenes médicas para el diagnóstico de neumonía mediante técnicas de Machine Learning*. <https://docta.ucm.es/entities/publication/94d0406d-1f69-4f5c-905d-d014bbddb727>