



Pontificia Universidad
Católica del Ecuador | Sede
Ambato

ESCUELA DE INGENIERÍAS

Tema:

**DESARROLLO DE UN SISTEMA PARA LA CLASIFICACIÓN DE IMÁGENES
MÉDICAS UTILIZANDO REDES NEURONALES CONVOLUCIONALES**

**Proyecto de investigación previo a la obtención del título de
Ingeniero en Sistemas de Información**

Línea de investigación:

TECNOLOGÍAS DE LA INFORMACIÓN Y LA COMUNICACIÓN

Autor:

Jhon Patricio Corrales Almendáriz

Director:

PhD. Ricardo Patricio Medina Chicaiza

Ambato – Ecuador

Agosto 2025

DECLARACIÓN DE AUTENTICIDAD Y RESPONSABILIDAD

Yo: **JHON PATRICIO CORRALES ALMENDÁRIZ**, con cédula de ciudadanía **0504351172**, autor del trabajo de graduación titulado: "DESARROLLO DE UN SISTEMA PARA LA CLASIFICACIÓN DE IMÁGENES MÉDICAS UTILIZANDO REDES NEURONALES CONVOLUCIONALES", previo a la obtención del título profesional de **INGENIERO EN SISTEMAS DE INFORMACIÓN**, en la escuela de **INGENIERÍAS**.

1. Declaro tener pleno conocimiento de la obligación que tiene la Pontificia Universidad Católica del Ecuador, de conformidad con el artículo 144 de la Ley Orgánica de Educación Superior, de entregar a la SENESCYT en formato digital una copia del referido trabajo de graduación para que sea integrado al Sistema Nacional de Información de la Educación Superior del Ecuador para su difusión pública respetando los derechos de autor.
2. Autorizo a la Pontificia Universidad Católica del Ecuador a difundir a través del sitio web de la Biblioteca de la PUCE Ambato, el referido trabajo de graduación, respetando las políticas de propiedad intelectual de la Universidad.

Ambato, agosto 2025



Jhon Patricio Corrales Almendáriz

CC. 0504351172

PONTIFICIA UNIVERSIDAD CATÓLICA DEL ECUADOR
SEDE AMBATO
APROBACIÓN DEL TRIBUNAL DE GRADO

Tema:

**DESARROLLO DE UN SISTEMA PARA LA CLASIFICACIÓN DE IMÁGENES
MÉDICAS UTILIZANDO REDES NEURONALES CONVOLUCIONALES**

Línea de investigación:

TECNOLOGÍAS DE LA INFORMACIÓN Y LA COMUNICACIÓN

Autor:

Jhon Patricio Corrales Almendáriz

Ricardo Patricio Medina Chicaiza, Ing. PhD.

CC. 1802333276

CALIFICADOR

Teresa Milena Freire Aillón, Ing. Mg.

CALIFICADOR

Galo Mauricio López Sevilla, Ing. Mg.

CALIFICADOR


Darío Javier Robayo Jácome, Ing. Mg.

DIRECTOR ESCUELA DE INGENIERÍAS

Diego Gonzalo Coca Chanalata, Dr.

SECRETARIO GENERAL PUCESA

f. 

f. 

f. 

f. 

f. 

Ambato – Ecuador

Agosto 2025

PONTIFICIA UNIVERSIDAD
CATÓLICA DEL ECUADOR
SECRETARÍA GENERAL
PROCURADURÍA

DEDICATORIA

A mi mamá, mi papá, mi hermana y mis abuelitos, por ser amorosos, pacientes y luchadores. Gracias por estar siempre conmigo, por su cariño incondicional y por apoyarme en cada paso de este camino. Su compañía y confianza han sido fundamentales para llegar hasta aquí. Este logro también es suyo.

A todos mis profesores, gracias por compartir sus conocimientos y enseñanzas con tanta dedicación. En especial, al Ing. Pato, por su guía y apoyo como tutor de tesis.

A mis compañeros de curso, con quienes compartí cuatro años de esfuerzo, aprendizaje y muchas vivencias. Gracias por estar ahí, por el apoyo mutuo y por todas las veces en que nos ayudamos a salir adelante.

Con todo mi cariño y gratitud.

AGRADECIMIENTO

A mi mamá, mi papá, mi hermana y mis abuelitos.

Gracias por estar a mi lado en cada paso de este trayecto, por su apoyo constante y por estar siempre atentos a lo que necesitaba, sin esperar nada a cambio. Su amor, paciencia y confianza han sido fundamentales para llegar hasta aquí.

Este logro no es solo mío, también es de ustedes.

RESUMEN

La neumonía es una de las principales causas de mortalidad a nivel mundial; por tanto, el diagnóstico debe ser preciso y en el tiempo que demanda la radiografía del tórax. El objetivo del trabajo de investigación es desarrollar un sistema para la clasificación de imágenes médicas utilizando redes neuronales convolucionales.

Se utilizó un conjunto de datos públicos “*Chest-X-Ray Images (Pneumonia)*” de la plataforma de Kaggle. Su desarrollo fue llevado a cabo en el entorno de Google Colab con las librerías TensorFlow y Keras. Se incluyó un procesamiento de las imágenes, una aplicación de aumento de datos (*data augmentation*), así como la creación de una propia arquitectura de red neuronal convolucional. Se trata de una arquitectura compuesta por 3 capas convolucionales secuenciales, cada capa con Normalización y una capa de agrupación máxima, seguidas de capas densas para clasificar las imágenes finales.

El modelo entrenado fue posteriormente validado en un conjunto de validación independiente, a partir de los resultados obtenidos, es posible concluir el rendimiento robusto del mismo, alcanzando una exactitud general de 91% y un Área Bajo la Curva ROC (AUC) de 0.98. Para la clase ‘neumonía’, el modelo alcanzó una precisión de 0.98 y una sensibilidad de 0.84, lo que pone de manifiesto su excelente capacidad para confirmar que un caso positivo lo es y su buena capacidad para detectarlos.

Palabras clave: red neuronal convolucional, aprendizaje profundo, clasificación de imágenes, neumonía, inteligencia artificial.

ABSTRACT

Pneumonia is one of the main causes of mortality worldwide; therefore, the diagnosis must be accurate and in the time that the chest radiograph demands. The objective of the research work is to develop a system for the classification of medical images using convolutional neural networks.

A public dataset, "Chest-X-Ray Images (Pneumonia)" from the Kaggle platform, was used. Its development was carried out in the Google Colab environment with the TensorFlow and Keras libraries. It included image processing, the application of data augmentation, as well as the creation of a custom CNN architecture. This architecture is composed of 3 sequential convolutional layers, each layer with Normalization and a Max Pooling layer, followed by dense layers to classify the final images.

The trained model was subsequently validated on an independent validation set. From the results obtained, it is possible to conclude its robust performance, achieving an overall accuracy of 91% and an Area Under the ROC Curve (AUC) of 0.98. For the 'pneumonia' class, the model reached a precision of 0.98 and a recall of 0.84, which demonstrates its excellent ability to confirm that a positive case is positive and its good ability to detect them.

Keywords: *convolutional neural network, deep learning, image classification, pneumonia, artificial intelligence.*

ÍNDICE GENERAL DE CONTENIDOS

DECLARACIÓN DE AUTENTICIDAD Y RESPONSABILIDAD	ii
APROBACIÓN DEL TRIBUNAL DE GRADO	iii
DEDICATORIA.....	iv
AGRADECIMIENTO.....	v
RESUMEN	vi
ABSTRACT	vii
INTRODUCCIÓN	1
CAPÍTULO I. ESTADO DEL ARTE Y LA PRÁCTICA.....	6
1.1. Acercamiento teórico a la inteligencia artificial en el sector médico	6
1.2. Redes neuronales artificiales: Definición y funcionamiento.....	9
1.3. Redes neuronales convolucionales (CNN): Arquitectura, aplicaciones y modelos.....	13
1.4. Métodos de análisis y procesamiento de imágenes para el diagnóstico de neumonía	17
CAPÍTULO II. DISEÑO METODOLÓGICO	22
2.1. Caracterización de la empresa o institución	22
2.2. Metodología de la investigación	25
2.3. Metodología de desarrollo.....	29
CAPÍTULO III. ANÁLISIS DE LOS RESULTADOS DE LA INVESTIGACIÓN	46
3.1. Validación del modelo	46
CONCLUSIONES.....	53
RECOMENDACIONES	54
BIBLIOGRAFÍA	55
ANEXOS	60

INTRODUCCIÓN

Las redes neuronales son un tipo de modelo computacional que busca imitar el procesamiento de información que hace el cerebro. Así, recuerda que el cerebro está hecho de neuronas, que son agrupaciones que procesan, modifican y envían información. Por eso, las redes neuronales están compuestas de neuronas (nodos interconectados en capas). Cada neurona recibe múltiples entradas, realiza su función de activación y emite una salida. Este mecanismo permite a las redes neuronales "aprender" lo que compone la información "compuesta", a través del entrenamiento para corregir fallos en su procesamiento interno (pesos sinápticos) para no errar y poder ser más eficientes en su función deseada (Goodfellow, Bengio, & Courville, 2016).

En cuanto a las redes neuronales convolucionales (CNN), es un tipo de red neuronal que se especializa para el procesamiento de datos específicos, como imágenes, señales o arquitectura basada en mallas. Las capas de una CNN se conforman con capas convolucionales que usan filtros para encontrar características estratificadas y significativas, el resultado que entregas es un nivel de complejidad computacional superior al de una arquitectura general. Estas capas convolucionales son ideales para las redes de reconocimiento, el procesamiento de imágenes y el trabajo con datos bidimensionales (LeCun, Bengio, & Hinton, 2015)

A nivel internacional, varias investigaciones muestran el valor y potencial de las redes neuronales.

Khan, Shah y Bhat (2020) evidenciaron que, para la clasificación de imágenes médicas las redes convolucionales tenían un potencial revolucionario. Esto se puede ver en el estudio de CoroNet, que se usó para la identificación de COVID-19 por medio de radiografías torácicas, usaron una arquitectura Xceptoin. Este modelo alcanzó una precisión del 89.6% en la clasificación de imágenes médicas, se destacó por su detección de casos de COVID-19, con una precisión del 93%. Los científicos mostraron estas redes como instrumentos adicionales eficientes para los radiólogos, capaces de modificar los métodos de diagnóstico. Este análisis es visto

como un avance significativo en el empleo de inteligencia artificial en el diagnóstico médico, con capacidades de mejorar la detección temprana y precisa de enfermedades.

Zhou, Liu, Bai y He (2024) descubrieron que las redes neuronales convolucionales constituyen un progreso considerable en el procesamiento de imágenes médicas, sugieren un Predictor Interpretable con Red Neuronal Difusa Convolutiva Profunda (IP-DCFNN). El modelo logró una mejora media del 7.4% en la precisión predictiva en comparación con sistemas adaptativos neuro difusos y redes neuronales profundas. Los científicos han desarrollado un método que fusiona la lógica con la informática convolutiva facilite así la recopilación de datos médicos con claridad interpretativa, este análisis se considera un avance significativo en la creación de modelos de inteligencia artificial capaces de dar diagnósticos médicos entendibles y personalizados.

Xuan y You (2020) investigaron las habilidades de las redes neuronales convolucionales para la identificación de tumores en páncreas, con ello crearon una Red Neuronal Convolutiva Jerárquica (HCNN) para la clasificación de imágenes de salud, el modelo consiguió avances destacables en la exactitud en la clasificación de tumores pancreáticos mediante imágenes de tomografía y resonancia magnética. Los científicos evidenciaron que esta metodología puede disminuir los gastos en las plataformas de Internet de las Cosas Médicas (IoMT) y proporcionar un instrumento no invasivo para el monitoreo y pronóstico de tumores. Se percibe este análisis como un progreso alentador en la utilización de inteligencia artificial para el diagnóstico precoz y exacto del cáncer de páncreas.

En el panorama nacional, se han iniciado proyectos pioneros que demuestran el compromiso de la comunidad científica ecuatoriana con la implementación de tecnologías de inteligencia artificial:

Ordoñez (2008) investigó las aplicaciones en el procesamiento de señales de voz con el uso de redes neuronales. Para ello realizó un trabajo práctico en el cual describe el diseño, pruebas y análisis de estructuras de redes neuronales aplicadas a la

compresión de señales de audio. En el desarrollo del trabajo también se realizaron programas que permiten crear, entrenar y analizar redes neuronales, con el objetivo de implementar una estructura útil en las telecomunicaciones. Los resultados corresponden a la eficiencia de las redes neuronales para comprimir las señales de voz. Se considera a este trabajo como una contribución interesante en la aplicación de redes neuronales en el procesamiento de señales de las telecomunicaciones.

Rivas y Mazón (2018) investigaron que las redes neuronales artificiales son planteadas como método de IA, esto pone en relieve su capacidad para simular el funcionamiento del cerebro humano a la hora de realizar la identificación de patrones. La investigación de este artículo incluye herramientas tecnológicas, ejemplos de aplicaciones y aplicaciones en múltiples áreas, como la medicina o la agronomía. Esto lleva a los autores a estudiar los elementos que configuran o describen la configuración, el funcionamiento y el potencial de las redes neuronales artificiales, con aportes evidenciales de su adaptabilidad en el manejo de datos y en la solución de problemas complejos. Este artículo destaca como un aporte significativo para conocer la capacidad de las redes neuronales artificiales en distintas áreas de la ciencia y la tecnología.

Silva (2022) exploró la aplicación de redes neuronales sintéticas para anticipar resultados en procesos de isomerización, creo un modelo capaz de prever la concentración molar de isobutano e isopentano. El cual usa DWSIM y Matlab, los investigadores idearon una red neuronal con veinte neuronas ocultas que alcanzo un coeficiente de correlación de 0,9990, esto demostró una precisión casi al nivel de un simulador. El estudio mostro un potencial grande de las redes neuronales para modelar procesos químicos complejos con alta exactitud.

El estudio y la obtención de un diagnóstico médico a partir de la interpretación de las imágenes que muestran radiografías, requiere de un alto grado de conocimiento y pericia por parte de los especialistas. Para enfermedades graves como la neumonía, una detección tardía o incorrecta podría llegar a ser fatal. Aunque los radiólogos poseen la habilidad para hacer cumplir ágilmente la interpretación de imágenes radiográficas, el proceso resulta ser laborioso y, además, puede estar

sometido al error humano, en especial en situaciones de alta demanda de servicios médicos. Por otro lado, en regiones donde se carece de personal especializado, el deficitario conocimiento sobre una adecuada interpretación de las imágenes radiográficas acentúa el problema, en cuanto que limita, por último, el acceso a un diagnóstico rápido y, también a un diagnóstico correcto y preciso.

El desarrollo de sistemas automáticos como herramienta para ayudar en el diagnóstico médico, simultáneamente con el aumento en la disponibilidad de imágenes médicas digitales e inteligencia artificial, permitiría aumentar la velocidad y la precisión en la detección de enfermedades y por tanto aumentar la posibilidad de detectar a tiempo enfermedades graves. Pero pese a que en los últimos años se han registrado muchas iniciativas, el desarrollo de modelos de inteligencia artificial suficientemente precisos y fiables como para ser utilizados en entornos clínicos resulta ser aún un reto. Esta es una problemática que se agudiza debido a la variabilidad en la calidad de las imágenes, la existencia de múltiples patologías y la necesaria problemática de aumentar el número de falsos positivos o falsos negativos.

¿Como poder realizar un modelo de red neuronal con el uso de un lenguaje de alto nivel para la clasificación de imágenes de tórax relacionadas a enfermedades pulmonares y garantizar un alto nivel de confianza en cuanto a su precisión?

La idea a defender es que con la creación de un sistema automático de clasificación de rayos X mediante redes neuronales mejora la precisión y rapidez en la detección de neumonía.

El objetivo general que consta en el proyecto es desarrollar un sistema para la clasificación de imágenes médicas utilizando redes neuronales convolucionales.

Los objetivos específicos del proyecto son analizar el estado del arte sobre redes neuronales convolucionales en la clasificación de imágenes médicas para diagnóstico de neumonía, con énfasis en métodos actuales y sus resultados, obtener un *dataset* de radiografías de tórax con imágenes etiquetadas para

diagnósticos de neumonía y elaborar una red neuronal convolucional para la clasificación de imágenes del *dataset*.

Para la ejecución de este proyecto se usa una metodología cuantitativa, y comprenderá la recopilación de datos, el pre-procesamiento de imágenes, la construcción de un modelo de redes neuronales convolucionales, y la evaluación con métricas como acierto, sensibilidad y especificidad. Se llevará a cabo una metodología incremental para ajustar y optimizar el sistema a lo largo del proceso de entrenamiento.

La justificación de esta investigación radica en la necesidad de mejorar la precisión y velocidad en el diagnóstico médico ha propiciado el desarrollo de herramientas tecnológicas para ayudar a los profesionales de la salud. La clasificación automática de imágenes médicas a partir de redes neuronales convolucionales en un lenguaje de alto nivel permite realizar grandes mejoras a la hora de disminuir el tiempo en el estudio del diagnóstico y mejorar la exactitud a la hora de detectar las enfermedades. Este estudio se enfoca en la construcción de un sistema que automatice la clasificación de radiografías de tórax para poder detectar neumonía.

La relevancia de este estudio radica en su potencial para mejorar el sistema de salud, con la proporción de una herramienta que ayude a los médicos, que pueda disminuir los tiempos y costes del diagnóstico médico.

Se espera desarrollar una interfaz simple y fácil de usar, con las siguientes características clave:

1. Carga de Imágenes: Sección para cargar radiografías de tórax.
2. Visualización de Resultados: Muestra los resultados de clasificación con la probabilidad de neumonía y métricas de precisión.

CAPÍTULO I. ESTADO DEL ARTE Y LA PRÁCTICA

Para entender correctamente el sistema que se ha desarrollado en esta tesis, es esencial examinar el estado del arte relacionado. Este capítulo tratará acerca de los fundamentos de la inteligencia artificial en el área de la medicina, los procesos de las redes neuronales y, en profundidad, las redes neuronales convolucionales como instrumento esencial para el estudio de imágenes médicas utilizadas en el diagnóstico.

1.1. Acercamiento teórico a la inteligencia artificial en el sector médico

La inteligencia artificial es uno de los campos tecnológicos más prometedores, permite a las máquinas realizar funciones que usualmente requieren de inteligencia humana, como es razonar, reflexionar y la toma de decisiones. En el ámbito médico, estas habilidades se emplean para aumentar la exactitud en el diagnóstico y optimizar el cuidado de pacientes. De acuerdo con Esteva et al. (2019), el aprendizaje profundo ha transformado la asistencia sanitaria al proporcionar instrumentos que superan las restricciones previas, posibilitando diagnósticos más rápidos y exactos.

La implementación de la inteligencia artificial en la medicina se originó con el avance de sistemas expertos a finales de la década de 1970, como los sistemas MYCIN, que demostraban cómo se podía emplear la inteligencia artificial en decisiones médicas específicas, aplicando ciertas normas fundamentadas en conocimiento como el diagnóstico de infecciones bacterianas (Shortliffe, 1976). Gracias al aumento de la capacidad de computación y al aumento de la cantidad de datos disponibles (*big data*), el avance de los algoritmos de aprendizaje profundo ha llegado a un nivel de complejidad que permite su utilización en varias disciplinas médicas (Esteva et al., 2019)

La inteligencia artificial es actualmente uno de los componentes esenciales del análisis de imágenes médicas, las técnicas de aprendizaje automático y aprendizaje profundo han transformado disciplinas como la radiología, la patología

digital y la oftalmología. Como puede verse, los procedimientos automatizados de aprendizaje automático son acertadamente eficientes cuando se utilizan algoritmos de redes neuronales convolucionales para localización de irregularidades mediante radiografías torácicas, para detección de tumores a partir de las imágenes que han sido capturadas a través de mamografía, para diagnóstico de enfermedades de la vista mediante imágenes en la retina (Litjens et al., 2017). Estos procedimientos mejoraron la precisión del diagnóstico y, además, disminuyeron el tiempo necesario para los estudios de imágenes.

Un caso que sirve plenamente para ilustrar esta realidad del uso de la IA en medicina es el sistema ideado por *Google Health* que se basa en redes neuronales para la detección del cáncer de mama a partir de mamografías. El sistema tiene una exactitud similar o mejor que la de los propios radiólogos expertos (McKinney et al., 2020). Otro ejemplo de empresas tecnológicas y hospitales que se unen para desarrollar herramientas de predicción de complicaciones quirúrgicas y herramientas que identifican patrones de las enfermedades en los estadios iniciales. Estos ejemplos ponen de relieve el potencial de la IA para complementar la actividad profesional de los expertos de la salud con mejores resultados clínicos y la disminución de la carga de trabajo.

No obstante, el alcance de la inteligencia artificial no se remite al diagnóstico. En el terreno de la medicina de precisión, los algoritmos de inteligencia artificial explotan grandes volúmenes de datos genómicos y clínicos para plantear tratamientos personalizados a las singularidades de los sujetos (Topol, 2019). Este es un principio crucial en áreas de enfermedades complejas como el cáncer, donde un tratamiento personalizado podría aumentar considerablemente los índices de efectividad y minimizar las reacciones adversas, la inteligencia artificial en la gestión hospitalaria se puede utilizar para mejorar la asignación de recursos, predecir las necesidades médicas y mejorar la logística de los servicios médicos.

Aunque posee ventajas, la integración de la inteligencia artificial en el ámbito médico supone desafíos de gran importancia. Uno de los retos más críticos es garantizar la calidad, diversidad y representatividad de los datos empleados para

entrenar los modelos de Inteligencia Artificial, los estereotipos presentes en los datos pueden provocar respuestas contradictorias o discriminatorias en la población con la que se trata (Obermeyer, Powers, Vogeli, & Mullainathan, 2019). Asimismo, la regulación y estandarización de las herramientas que incorporan IA son aspectos pendientes que se tienen que atender para asegurar su utilización segura y ética en el campo de la clínica. Se sigue con el estudio y la observación de la necesidad urgente que los profesionales sanitarios reciban conocimiento acerca del funcionamiento y limitaciones de la IA para fomentar tanto la confianza como la implementabilidad de la misma.

En circunstancias donde los recursos disponibles son escasos, la IA podría ofrecer una solución bastante satisfactoria que permitiera derribar los obstáculos al acceso de un buen uso de los servicios de salud. En el caso de comunidades rurales en las que la presencia del personal profesional es baja, el uso de la IA podría de alguna forma ayudar a generar el diagnóstico inicial para que los médicos generales reconozcan la existencia de enfermedades complejas (Rajpurkar et al., 2018). No sería un elemento que solo mejoraría la calidad en el caso de comunidades no atendidas, sino que además podría provocarle una disminución de las desigualdades sanitarias a nivel global.

Según las proyecciones actuales de la IA aplicada en medicina, en el futuro será sorprendente, dado que se incluirán tecnologías emergentes como la computación cuántica, la inteligencia artificial explicativa (Explainable AI) o los sistemas de aprendizaje federado. De esta forma, darán nuevas alternativas para poder implementar modelos más difíciles de modelar, más transparentes y más seguros. Como se ha observado en la evolución histórica de la Inteligencia Artificial, la cooperación entre las instituciones académicas, la industria tecnológica y los sistemas sanitarios va a ser esencial para potenciar el efecto de la IA en la medicina, además de promover el conocimiento y la propagación de sus ventajas, sin importar el lugar de residencia o el colectivo social.

Por lo cual, la Inteligencia Artificial ha demostrado ser un recurso efectivo en el campo médico, con resultados en la facilitación en el diagnóstico, tratamiento y

prevención de enfermedades. Existen diversos retos a vencer, sin embargo, la Inteligencia Artificial tiene un potencial extraordinario para ayudar a mejorar los resultados clínicos y perfeccionar las prácticas. Además de ser capital en la actualidad y en el futuro de la medicina, la IA también tiene como objetivo poder democratizar la atención médica. De forma alternativa, este acercamiento teórico además justifica dónde se han producido los avances históricos hasta el momento, así como la necesidad de seguir con la investigación y el desarrollo de soluciones que optimicen los beneficios de la IA para la humanidad.

1.2. Redes neuronales artificiales: Definición y funcionamiento

Las redes neuronales artificiales (RNA) constituyen una de las bases de la inteligencia artificial moderna. Con una orientación hacia la estructura y al funcionamiento del cerebro humano, estas han otorgado un importante cambio en muchas áreas, esto ofrece respuestas a problemas complejos. De una forma sencilla, una RNA puede definirse como un sistema computacional que permite simular la forma en la que las neuronas biológicas procesan información (Goodfellow et al., 2016).

El origen del concepto de RNA tiene sus antepasados en la década de 1940 cuando surge el modelo de McCulloch-Pitts, el cual intenta reproducir la actividad de las neuronas biológicas desde un enfoque matemático. Este modelo necesariamente rudimentario fue el que sentó las bases del desarrollo de sistemas más complejos, los cuales en un trabajo posterior han cambiado y evolucionado paulatinamente a partir de la evolución en el ámbito del poder computacional y de la disponibilidad de datos (McCulloch & Pitts, 1943). A pesar de que la RNA esté inspirada en el mismo cerebro humano, no intenta reproducirlo tal cual sino capturar ciertos principios generales de cómo se procesa información.

Una Red Neuronal Artificial (RNA) se organiza comúnmente en capas de neuronas. La capa inicial, o capa de entrada, es la que recibe los datos primarios para ser analizados. Posteriormente, una o más capas ocultas procesan la información a través de la mayoría de los cálculos y transformaciones de datos. La capa final,

denominada capa de salida, genera el resultado del procesamiento de la red. Cada neurona está conectada a las neuronas de la capa anterior, y estas conexiones son ponderadas por un parámetro llamado "peso". Estos pesos se ajustan durante el proceso de entrenamiento de la red, lo que permite que el modelo se adapte para aproximar funciones de alta complejidad y aprenda a identificar patrones en los datos (Molina, 2025)

El proceso operativo de las Redes Neuronales Artificiales (RNA) se inicia con la propagación de la información hacia adelante, donde los datos de entrada atraviesan la red capa por capa. En cada neurona, la información ponderada recibida se transforma mediante una función de activación, la cual es un componente crucial que introduce no linealidad en el sistema. Esta no linealidad, aportada por funciones como ReLU (Unidad Lineal Rectificada), Sigmoide o la Tangente Hiperbólica, es lo que capacita a la red para modelar y aprender las relaciones complejas inherentes a los datos del mundo real. A medida que la información avanza a través de las capas ocultas, la red aprende a extraer de manera automática y jerárquica características cada vez más abstractas y relevantes, transformando progresivamente los datos brutos en representaciones de alto nivel que son útiles para la tarea final, ya sea de clasificación o regresión (Restrepo Leal, 2021).

El aprendizaje en las redes neuronales artificiales se realiza a través de un método denominado retro propagación del error. En el proceso de aprendizaje, la RNA compara su salida con el resultado esperado y se calcula el error o pérdida. Con dicho error, se aprenden los pesos de las conexiones mediante un algoritmo de optimización (descendiente de gradiente); este proceso de propagación hacia delante y retro propagación se repite de forma iterativa hasta que se alcanza un rendimiento aceptable. Este proceso permite a las redes neuronales aprender patrones automáticamente mediante retropropagación del error y optimización por descenso de gradiente, incluso en arquitecturas de valores complejos (Hammad, 2024).

Uno de los avances más destacados de las RNA o Redes Neuronales Artificiales es el denominado aprendizaje profundo o *deep learning*, con el que se configura un modelo que se fundamenta en las RNA, este construye un gran número de capas ocultas que corresponden a RNA profundas y que se emplean principalmente para resolver problemáticas complejas asociadas a cantidades de datos muy grandes. Las redes neuronales profundas aprenden representaciones jerárquicas, donde las capas iniciales capturan características simples y las superiores extraen patrones más abstractos; este paradigma ha impulsado avances en visión por computador, procesamiento del lenguaje natural y generación de contenido (Hammad, 2024).

Un ejemplo paradigmático del funcionamiento de las redes neuronales es por ejemplo cuando se usa redes neuronales para el reconocimiento de imágenes. Para esta tarea, una red convolucional opera con imágenes, las redes neuronales convolucionales procesan imágenes por fragmentos, aplicando filtros que detectan bordes, texturas y formas; a medida que se combinan sus capas, se logra el reconocimiento o clasificación precisa de objetos, con aplicaciones en diagnóstico médico, conducción autónoma y seguridad (Xiao, 2024).

Las redes neuronales recurrentes (RNN), junto con la clasificación de la imagen, constituyen otra categoría de arquitectura capaz de manejar datos secuenciales (texto, señales de sonido, etc.), que, a diferencia de las redes neuronales tradicionales, las RNN incluyen conexiones que permiten recordar pasos anteriores, lo cual es esencial para comprender el contexto o las dependencias en secuencias temporales. Este modelo ha sido ampliamente utilizado en tareas como la traducción automática, la generación de texto y los sistemas de recomendación (Yu, Si, Hu, & Zhang, 2019).

El éxito de las redes neuronales artificiales no solo depende de la arquitectura utilizada, sino también de la manera eficiente con que estas redes son alimentadas por grandes volúmenes de datos y potencia computacional. El desarrollo de hardware especializado, como las TPU (*Tensor Processing Units*), ha acelerado significativamente la capacidad de entrenar estas redes de manera eficiente (Jouppi et al., 2022). Por otro lado, las técnicas de regularización, como el *dropout*, la

normalización por lotes (*batch normalization*) y métodos más recientes como *mixup* y *label smoothing*, han mejorado la generalización de los modelos al combatir el sobreajuste a los datos empleados durante el entrenamiento (Nusrat & Jang, 2018).

A pesar de sus extraordinarias capacidades, las redes neuronales presentan también importantes limitaciones. Una de las principales es su dependencia de grandes cantidades de datos etiquetados para lograr un aprendizaje adecuado y eficiente, lo que puede ser una barrera en ámbitos donde obtener dichos datos resulta costoso o difícil (Jin et al., 2023). Además, las redes neuronales artificiales suelen considerarse como un sistema de tipo caja negra, entender y explicar su funcionamiento interno es complejo, lo que genera problemas de transparencia y confianza, especialmente en contextos críticos como el médico o el judicial (Xu & Yang, 2025).

El estudio actual en redes neuronales intenta superar tales restricciones. Una de las perspectivas más prometedoras es la inteligencia artificial explicable (XAI, por sus siglas en inglés), que se centra en desarrollar técnicas para comprender las decisiones de las RNA, lo cual incrementa no solo la confianza en los modelos, sino también su aplicación en sistemas donde la rendición de cuentas es necesaria. Por otro lado, el aprendizaje auto supervisado permite que las redes neuronales adquieran conocimiento a partir de datos no etiquetados, mejorando su aplicabilidad en contextos con recursos limitados (Schneider, 2024).

El futuro de las redes neuronales artificiales prevé, a su vez, innovaciones a las ya vistas. La asociación con tecnologías emergentes, tales como la computación cuántica, podría permitir a las RNA rendir en escalas de magnitud completamente nuevas. Las mismas RNA, en combinación con otros paradigmas de la inteligencia artificial, por ejemplo, los modelos tradicionales basados en la lógica simbólica, podrían, además, permitir solventar algunas de sus limitaciones actuales en la generación de sistemas híbridos más robustos y potentes (Henderson et al., 2024).

Las redes neuronales artificiales constituyen un nuevo paradigma en inteligencia artificial. Las redes neuronales artificiales han servido para resolver problemas

complejos y han llevado a la comunidad científica a importantes avances en distintos ámbitos: sanidad, ocio, etc. A pesar de todo, hay que tener en cuenta que las redes neuronales artificiales presentan limitaciones a nivel técnico y ético, lo cual no impide que sigan con su evolución y que la comunidad científica esté dispuesta a comprometerse con ellas; lo cual dibuja un futuro garantizado. Las RNA no han revolucionado solamente la forma que se tiene de entender la tecnología, sino también la forma de resolver problemas complejos que parecían inalcanzables.

1.3. Redes neuronales convolucionales (CNN): Arquitectura, aplicaciones y modelos

Las Redes Neuronales Convolucionales (CNNs, por sus siglas en inglés) son una clase de modelos de aprendizaje profundo que ya han demostrado ser buenos e influyentes en el campo de la inteligencia artificial. Se inspiran parcialmente en la organización jerárquica del córtex visual humano, las CNNs son idóneas para procesar datos que poseen una estructura de rejilla, como imágenes, esto las convirtió en herramientas fundamentales para tareas que necesitan interpretación de datos visuales y espaciales, como la visión por computadora, el diagnóstico médico asistido por imagen, la robótica y algunas aplicaciones para procesamiento de lenguaje natural (LeCun et al., 2015).

La arquitectura de una red neuronal convolucional es diferente a una red neuronal (NN, en inglés) tradicionales por la utilización de una operación matemática llamada convolución. Esta operación se refiere a la capacidad de aprender características locales en los datos, especialmente en las imágenes, de una forma más eficaz que otros tipos de redes neuronales (Goodfellow et al., 2016).

Cuando se trabaja con información que se organiza como una cuadrícula, como las fotos, las Redes Neuronales Convolucionales (CNNs) son un gran avance en comparación con las redes neuronales de siempre. Lo que se hace es que en vez de conectar cada neurona con todas las demás, las CNNs usan como "lentes" especiales, llamados *kernels*, que miran la imagen por pedacitos. Estos "lentes" hacen un cálculo, una convolución, en cada pedacito. Lo interesante es que estos

"lentes" usan los mismos números, los mismos pesos, en toda la imagen. Esto es genial porque reduce mucho la cantidad de cosas que la red tiene que aprender, y además le da la capacidad de encontrar cosas como bordes o texturas, sin importar dónde estén en la imagen, algo que se llama equivarianza a la traslación. Al final, lo que se obtiene son mapas de características, que dice dónde la red encontró lo que se buscaba, los patrones que cada "lente" reconoce. (IBM Cloud Education, 2023).

El esquema que adopta una CNN suele ser el siguiente, donde se encuentran tres capas distintas: capa de convolución, capa de activación y la capa de agrupamiento. En efecto la capa de convolución realiza una operación mediante filtros a la imagen, extrae las características locales y la capa de activación confiere no linealidad al sistema, de tal manera que la red puede hacer su trabajo y aprovechar conexiones complejas en los datos. Una de ellas, una de las más utilizadas es la llamada ReLU (Rectified Linear Unit), que ha demostrado ser eficaz para acelerar el entrenamiento de redes (Nair & Hinton, 2010). A su vez las capas de agrupamiento (*pooling*), permiten reducir la dimensionalidad de las representaciones que genera la capa de convolución y, así, también los parámetros y tiempos de procesamiento.

Además de las capas mencionadas anteriormente, las CNN frecuentemente incluyen capas totalmente conectadas (*fully connected layers*), que son las mismas que comúnmente tiene una red neuronal tradicional y generalmente se encuentran al final de la red. Estas capas permiten a la CNN llevar a cabo labores de clasificación o regresión y combinar globalmente las características de alto nivel obtenidas de las capas anteriores (Goodfellow et al., 2016). Esta organización jerárquica, desde características simples detectadas por los primeros filtros hasta conceptos más complejos aprendidos en capas profundas, posibilita que las redes convolucionales obtengan representaciones cada vez más abstractas de los datos de ingreso.

Si bien la estructura descrita es la base para tareas de clasificación, es importante mencionar que existen distintos "tipos" o variaciones de arquitecturas CNN

adaptadas a tareas específicas. Por ejemplo, hay modelos diseñados para la detección de objetos (localizar y clasificar múltiples objetos) o para la segmentación semántica (clasificar cada píxel). En el ámbito médico, arquitecturas como U-Net son un ejemplo de CNN especializada, optimizada para la segmentación precisa de estructuras en imágenes biomédicas (Ronneberger, Fischer, & Brox, 2015).

El procedimiento de formación de una red neuronal convolucional se asemeja al de otras redes neuronales, aunque posee sus características únicas, en primer lugar, los datos de entrada, que suelen ser imágenes, son pasados por la red, puesto que los filtros que actúan en la red aplican convoluciones para extraer características. A continuación, la red calcula una salida que es comparada con el valor deseado con el uso de una función de pérdida como la entropía cruzada en el caso de la clasificación (Goodfellow et al., 2016). Finalmente, el error resultante es retropropagado a través de la red, se ajustan los pesos de los filtros y los de las capas completamente conectadas de acuerdo con un algoritmo de optimización como el descenso de gradiente.

Uno de los desafíos significativos en el entrenamiento de una red neuronal convolucional es el aprendizaje apropiado de los filtros y la adecuada disposición de los parámetros de la red. En una red convolucional, los filtros no poseen una producción preestablecida si no son adquiridos durante el proceso de entrenamiento. En los niveles iniciales de la red, los filtros tienen la habilidad de adquirir características sencillas como bordes y texturas, mientras que, en las capas más avanzadas, los filtros adquieren características más complejas y abstractas como las formas u objetos. Esta habilidad para aprender las características jerárquicamente es lo que convierte a las CNNs en particular valiosas en el contexto de las tareas de reconocimiento de imágenes (Krizhevsky, Sutskever, & Hinton, 2017)

Las CNN han sido capaces de demostrar su efectividad en una notable cantidad de aplicaciones, bastante especialmente en el ámbito de la visión artificial. Uno de los logros más importantes que han hecho posible las CNN es el reconocimiento de objetos a partir de imágenes, el que se ha llevado a su explotación en aplicaciones

como el reconocimiento facial, el análisis de escenas o el coche autónomo (Krizhevsky et al., 2017). En la medicina, las redes neuronales convolucionales han podido aportar un gran logro a la forma diagnóstica de las imágenes médicas, y en especial el diagnóstico de enfermedades a partir de radiografías, tomografías o resonancias magnéticas.

Así también, en la oftalmología, se han utilizado las CNN para detectar enfermedades en la retina a partir de fotografías, las que han permitido incrementar la exactitud y disminuir el tiempo necesario para realizar los diagnósticos (Litjens et al., 2017). Estas mejoras han probado ser un significativo progreso en la mejora de la atención sanitaria, dado que facilitan la obtención de diagnósticos más veloces y precisos, incluso en contextos donde los recursos son limitados.

En adición a su utilización en las imágenes médicas, las redes neuronales convolucionales también han tenido un impacto en otras disciplinas como la agricultura, la robótica o la seguridad, la agricultura es un buen ejemplo del uso de las redes neuronales convolucionales para analizar imágenes de cultivos y detectar (de manera temprana) signos de enfermedades o plagas, lo que permite a los agricultores tomar decisiones respecto a la manera de gestionar el cultivo (Kamilaris & Prenafeta-Boldú, 2018)

Durante los años se han propuesto y desarrollado varios modelos de redes neuronales convolucionales que han marcado un avance en el progreso de la visión por computadora y el aprendizaje profundo, uno de los modelos principales es el LeNet-5 propuesto por Yann LeCun en 1998. LeNet-5 fue uno de los primeros modelos en demostrar que las redes convolucionales podían ser útiles para el reconocimiento de caracteres manuscritos (LeCun et al., 2015). De hecho, dicho modelo fue la base para el desarrollo de redes convolucionales más profundas y complejas. Otro modelo importante es el AlexNet que ganó el concurso de clasificación de imágenes ImageNet en 2012, un modelo que usa una red más profunda que la LeNet-5 y que utiliza técnicas de regularización como el *dropout* que permiten evitar el sobreajuste, mejoró el rendimiento en datos de prueba (Krizhevsky et al., 2017).

Desde la publicación de AlexNet aparecieron diferentes modelos más avanzados con arquitectura mejorada de las redes convolucionales y de la efectividad de las mismas; por ejemplo, VGGNet, ResNet o Inception. VGGNet se caracterizó por su simplicidad y profundidad mediante una arquitectura de redes de convoluciones de pequeña dimensión, pero de profundidad grande. Por su parte, ResNet, que introdujo las "conexiones residuales" que permiten a las redes profundas ser entrenadas de una forma más efectiva que las redes antiguas que podían caer en el problema del desvanecimiento del gradiente. Y por último Inception, que mejoró la arquitectura con capas de filtros de diversas dimensiones.

El modelo más actual que ha revolucionado la visión por computadora es el EfficientNet, que obtiene la mejor eficiencia de las CNNs. EfficientNet otorga un modelo que optimiza la búsqueda de la arquitectura neural (*neural architecture search*) para encontrar el mejor modelo con el coste menor. Este modelo de EfficientNet ha establecido nuevos patrones en cuanto a la relación de la efectividad general y la eficiencia, esto ayuda a que las redes neuronales convolucionales sean cada vez más accesibles para una gran variedad de aplicaciones, hasta las que tienen recursos muy limitados (Tan & Le, 2019).

1.4. Métodos de análisis y procesamiento de imágenes para el diagnóstico de neumonía

La neumonía, que ha sido definida como una de las afecciones respiratorias más frecuentes y con una competencia con un riesgo de muerte elevado y una incidencia muy destacada, constituye un importante reto para los sistemas de salud a nivel mundial. De igual modo, la identificación de esta enfermedad mediante diagnóstico precoz es un prerrequisito para la prevención de complicaciones severas. Eso sí, los métodos diagnósticos convencionales no carecen de limitaciones en diversas facetas como el tiempo, costes y subjetividad. Por otra parte, el análisis y procesamiento de imágenes médicas se han establecido en el lugar actual como unas de las herramientas fundamentales cara a incrementar la efectividad en el diagnóstico (Litjens et al., 2017). Este epígrafe hace referencia a los métodos básicos que usan, tanto en el análisis como en el procesamiento de

las imágenes médicas, por lo que se estudian y abarcan técnicas clásicas y técnicas punteras, apoyadas en la inteligencia artificial.

Desde el punto de vista histórico, el diagnóstico de la neumonía se basó en su lectura por los radiólogos expertos de las radiografías de pecho. Esta técnica todavía es el standard, dado que hay equipos de rayos X en todos los lados y que permiten la visualización de características bien definidas como son las opacidades pulmonares. No obstante, la lectura manual está muy condicionada por la experiencia del radiólogo y puede ser propensa a errores de diagnóstico, en especial en ciertos casos de neumonías atípicas o en radiografías que presentan artefactos que obstaculizan el análisis. Asimismo, en regiones con pocos recursos y una escasez de radiólogos de formación, pueden aparecer demoras diagnósticas y una mayor propensión de complicaciones (Kamilaris & Prenafeta-Boldú, 2018).

La llegada del procesamiento digital de imágenes ha comenzado a transformar el diagnóstico médico mediante la incorporación de técnicas computacionales que mejoran la calidad de las imágenes y optimizan su interpretación. De esta manera, el resaltado del contraste, la subsunción del ruido, la segmentación de las áreas de interés, etc. permiten ver mejor las zonas afectadas de los pulmones. Por ejemplo, las técnicas de filtrado adaptativo reducen el ruido de la radiografía sin dejar de lado el mantenimiento del detalle, lo que resulta cómodo para imágenes de mala calidad obtenidas en situaciones adversas (Goodfellow et al., 2016).

Con la llegada de la tecnología, las técnicas basadas en el análisis de características se han vuelto fundamentales para el desarrollo del diagnóstico automatizado. Estas técnicas extraen atributos importantes de las imágenes, como la textura, la forma o la intensidad de las regiones pulmonares. Las imágenes son analizadas para identificar patrones asociados a la neumonía, como la presencia de consolidaciones o infiltrados intersticiales. Esta línea de trabajo ha permitido la creación de sistemas de soporte a la decisión médica que ofrecen a los médicos una segunda opinión mediante análisis objetivos (Kumar et al., 2022).

En años recientes, las técnicas de la inteligencia artificial han revolucionado el campo del análisis de imágenes médicas en tanto que las redes neuronales convolucionales (CNN en inglés) promovieron el auge de estas. Las CNN son un tipo muy particular de red neuronal artificial que surge de la búsqueda de técnicas de red neuronal artificial con propiedades para el procesamiento de datos visuales. Son redes que aplican capas convolucionales para aprender automáticamente las características que son relevantes del conjunto de datos en vez de realizar la extracción de forma manual. Este enfoque ha sido demostrado como habitual para clasificar imágenes de los tórax y el diagnóstico de neumonía con niveles de precisión como los de un radiólogo (Krizhevsky et al., 2012).

Como ocurre en el diagnóstico de neumonías, el entrenamiento del modelo de las CNN se efectúa en grandes conjuntos de datos de imágenes de rayos X de tórax, como el conjunto de imágenes ChestX-ray14 que fue desarrollado por los Institutos Nacionales de Salud (NIH) en Estados Unidos. Este conjunto tiene una base de datos de imágenes de más de 100,000 imágenes que están etiquetadas con las distintas patologías de los pulmones, incluida la neumonía. El conjunto también ha sido utilizado para evaluar la eficacia de los modelos de aprendizaje profundo (Wang et al., 2017). Los modelos obtenidos con este conjunto aprenden las características necesarias para identificar los patrones sutiles que el ojo humano no podría reconocer. Esto se traduce finalmente en una mejora de la sensibilidad y especificidad del diagnóstico.

Las técnicas de procesamiento de imágenes, además de ser utilizadas por la comunidad científica para el diagnóstico de la enfermedad, pudiéndose incluso conseguir cuantificar la neumonía, también pueden ser integradas en modelos mucho más complejos, para lograr la segmentación de las áreas dañadas en los pulmones mediante el procesamiento y la aplicación de determinadas métricas, como por ejemplo el porcentaje de opacidad en los pulmones. Con estas métricas se puede llegar a obtener información útil para poder evaluar la progresión de la neumonía, así como controlar la eficacia del tratamiento, y de hecho durante la pandemia del COVID-19 se utilizó este tipo de herramientas para controlar la extensión del daño en los pulmones de pacientes ingresados, y, por lo tanto, ayuda

a los médicos en la toma de decisiones clínicas sobre los pacientes (Litjens et al., 2017).

Otra aproximación en procesamiento de imágenes prometedora y que ha dado buenos resultados ha sido el uso de modelos de aprendizaje transferido. En el caso del aprendizaje transferido, se utiliza un modelo que ha sido preentrenado en una tarea general, como clasificar imágenes en el *dataset* ImageNet, el cual se adapta posteriormente para el diagnóstico médico. Este tipo de aproximación es muy útil cuando el conjunto de datos médicos es escaso y en el que es capaz de explotar el conocimiento previamente adquirido durante el preentrenamiento del modelo para mejorar su rendimiento en una tarea específica (Goodfellow et al., 2016).

La inteligencia artificial también se ha aplicado a aplicaciones reales, como aplicaciones para teléfonos móviles y plataformas en la nube que permiten a los médicos subir imágenes de rayos X y recibir diagnósticos, a partir de esas imágenes, en segundos. Estas soluciones son especialmente relevantes en áreas rurales o de niveles socioeconómicos muy bajos que pueden carecer de médicos radio logistas. Esta tecnología democratiza el acceso a tecnologías avanzadas, estas herramientas tienen el potencial de contribuir a la reducción de las desigualdades en asistencia médica y a una mejora de los resultados de salud a nivel global (Kamilaris y Prenafeta-Boldú, 2018).

El diagnóstico de la neumonía por medio de imágenes ha mejorado notablemente, aunque el procesamiento y análisis de imágenes es un reto en múltiples ocasiones; en gran medida, por una de las principales dificultades existentes por parte de los algoritmos, la cual se encuentra muy relacionada con la calidad y representatividad de los datos que pueden ser o fueron las que entrenaron a los modelos. Es importante destacar que muchas de las bases de datos tienen imágenes generadas a partir de una población, por lo general, una población particular y, por lo tanto, esto limita la capacidad del modelo para generalizar con respecto a otras poblaciones (Zhou et al., 2021). El material también puede variar según la calidad de imagen que se obtiene de los equipos de rayos X existentes en el hospital, así como de la eficacia de captura, lo que indica que también existen modelos que son

robustos ante estas variaciones (Gulshan et al., 2016)

Tal interpretación puede permitir a los modelos de IA que sean comprensibles; porque efectivamente, a pesar de la potencia que ofrecen los modelos de CNN, y que tienen un enfoque de "caja negra", esto dificulta la visualización de la manera en la que el modelo toma la decisión en este contexto (Samek, Wiegand, & Müller, 2017). Esta dificultad provoca la desconfianza de los clínicos, que consideran que deben conocer la base de cada recomendación para poder implementarla en su práctica clínica. Esta problemática se ha tratado de reformular mediante el diseño de sistemas de IA explicativa (Explainable AI), que permiten visualizar qué áreas de la imagen son las que más han influido en la decisión del modelo; de este modo se equipara con un poco más de transparencia y confianza (Selvaraju et al., 2019).

El análisis y procesamiento de imágenes tiende a seguir una tendencia creciente hacia métodos más precisos; la IA federativa, por ejemplo, tiende a ser un sistema que permite entrenar modelos a partir de imágenes generadas desde múltiples instituciones, esto evita la necesidad de compartir datos sensibles, pues a través de esta metodología los datos de los pacientes quedan preservados (Yang et al., 2019). Así, el hecho de integrar imágenes médicas y registros electrónicos de salud y datos genómicos puede propiciar una mayor eficacia y personalización del modelo (Topol, 2019).

La forma en que los métodos de análisis y procesamiento de imágenes han transformado el diagnóstico de la neumonía para convertirlo en más rápido, más preciso y más accesible, desde técnicas tradicionales de mejora de imágenes al uso de modelos más avanzados basados en inteligencia artificial, este sigue en crecimiento para superar nuevos retos a los que se enfrenta el sector de la salud. Estas herramientas continúan en desarrollo para superar los retos presentes y el hecho de que la práctica clínica las haga suyas y las haga más habituales haría que el impacto revitalizador de éstas produzca unos resultados sobre la salud inmensos, esto marcaría un hito en la lucha contra esta patología respiratoria tan crítica (Litjens et al., 2017).

CAPÍTULO II. DISEÑO METODOLÓGICO

En el presente capítulo se describe a detalle la metodología de desarrollo del sistema de clasificación de imágenes.

2.1. Caracterización de la empresa o institución

La arquitectura constitucional de Ecuador sitúa el derecho a la salud como pilar fundamental, y por ello el Estado tiene la obligación de garantizar cobertura sanitaria universal y gratuita en todos los niveles asistenciales. El Sistema Nacional de Salud (SNS) en Ecuador funciona como una combinación de servicios públicos y privados. Sin embargo, esta mezcla presenta una gran falta de coordinación entre sus partes (OPS, 2012).

Dentro del sistema, el sector público es el que más servicios ofrece. Está compuesto principalmente por el Ministerio de Salud Pública (MSP) y el Instituto Ecuatoriano de Seguridad Social (IESS). El MSP tiene la tarea de dirigir y organizar todo el sistema de salud. Esto incluye crear políticas y normas sanitarias, planificar el funcionamiento del sistema y brindar atención médica directa a las personas que no tienen seguro social.

Para ello, despliega una red de establecimientos organizados según complejidad asistencial (OPS, 2012).

De forma paralela, el IESS centra su acción prestacional en la población afiliada que incluye trabajadores formales, independientes adscritos voluntariamente, jubilados y beneficiarios del seguro campesino junto a sus dependientes directos. Este instituto gestiona su propia red sanitaria, dotada de unidades de diversa capacidad resolutoria. A estos dos grandes ejes se añaden subsistemas públicos de menor dimensión, tales como los servicios médicos castrenses y policiales (OPS, 2012).

Además, del entramado público, el sector privado despliega una oferta variada. Esta abarca desde la consulta médica individual y clínicas de estructura sencilla hasta complejos hospitalarios de vanguardia y centros especializados en diagnóstico. Si bien su alcance demográfico es más restringido, orientado a usuarios con capacidad de pago directo o seguros privados, su contribución es relevante en determinadas áreas terapéuticas y geográficas, y con diversificación el panorama sanitario global (OPS, 2012).

Con todo, la aspiración a una cobertura universal efectiva y el fortalecimiento del SNS enfrentan obstáculos persistentes. La propia fragmentación estructural del sistema es un generador reconocido de ineficiencias operativas y de notorias disparidades en el acceso y la calidad de la atención sanitaria recibida por la ciudadanía. Estas brechas se hacen especialmente patentes al contrastar las realidades urbanas con las rurales, o al examinar distintos estratos socioeconómicos (OPS, 2012). Adicionalmente, la ecuación financiera del sistema, la distribución equitativa y la suficiencia de personal sanitario cualificado a lo largo del territorio, así como la modernización y disponibilidad de tecnologías médicas – sobre todo en la red secundaria y terciaria alejada de los grandes polos urbanos –, configuran nudos críticos que demandan soluciones estratégicas y sostenidas.

En la arquitectura jerarquizada del SNS ecuatoriano, los hospitales asumen un rol pivotal en la dispensación de atención especializada y en la resolución de contingencias sanitarias de alta complejidad, aquellas que exceden la capacidad resolutoria del primer nivel de atención (centros de salud). La propia clasificación de estos establecimientos, emanada del MSP, se articula en función de niveles asistenciales y potencial resolutorio (OPS, 2012).

Los hospitales se emplazan predominantemente en los niveles segundo y tercero. Los denominados Hospitales Básicos (usualmente en el segundo nivel) ofertan un núcleo de servicios en medicina general, pediatría, gineco-obstetricia y cirugía general, con capacidad para hospitalización elemental. Por su parte, los Hospitales Generales, también mayoritariamente de segundo nivel, pero dotados de una capacidad resolutoria superior a los básicos, conforman la espina dorsal de la red

hospitalaria nacional. Su diseño está orientado a proporcionar un espectro más amplio de prestaciones médicas y quirúrgicas en las cuatro especialidades clínicas fundamentales (medicina interna, pediatría, gineco-obstetricia, cirugía general), y es frecuente que su cartera de servicios incorpore otras disciplinas troncales como traumatología, cardiología, anestesiología y un aspecto de interés capital para este estudio radiología e imagenología (Ministerio de Salud Pública del Ecuador, 2013).

Funcionan como nodos de referencia para los establecimientos de atención primaria y los hospitales básicos de su área geográfica de influencia, estos Hospitales Generales suelen constituir el primer escalón de atención hospitalaria para pacientes con condiciones agudas o crónicas descompensadas. Las distintas clínicas pueden exigir diagnóstico especializado, ingreso hospitalario, tratamiento intensivo, lo que sucede con los casos paradigmáticos de neumonías severas o moderadas. El arsenal diagnóstico del hospital, que consideramos como ciertas pruebas de laboratorio, pero también como ciertos servicios de imagen (radiografía simple, ecografía y tomografía computarizada en algunos hospitales) es fundamental para realizar la adecuada técnica para el desarrollo de aquellas. La rapidez y precisión de los recursos diagnósticos influye sobre las decisiones clínicas y, por tanto, sobre el pronóstico de los pacientes (Ministerio de Salud Pública del Ecuador, 2013).

El tercer nivel asistencial se reserva para los Hospitales de Especialidades y los Hospitales Especializados. Estos centros cuentan con la máxima capacidad resolutive del sistema, incorporan tecnología de punta y disponen de personal subespecialidad para el manejo de patologías de elevada complejidad o baja prevalencia epidemiológica. Si bien la sospecha diagnóstica inicial de una neumonía puede surgir en cualquier nivel del sistema, los casos que presentan mayor gravedad o desarrollan complicaciones son habitualmente derivados a estos centros de alta complejidad. No obstante, es indiscutible que el peso cuantitativo principal del diagnóstico y manejo terapéutico de la neumonía, tanto adquirida en la comunidad como nosocomial, descansa sobre la capacidad instalada de los Hospitales Generales (Ministerio de Salud Pública del Ecuador, 2013).

Dentro del ámbito hospitalario, diversos especialistas médicos interactúan en la secuencia diagnóstica de la neumonía. Facultativos de servicios de urgencias, medicina interna, pediatría y neumología efectúan la evaluación clínica inicial y prescriben estudios imagenológicos pertinentes. La responsabilidad interpretativa de dichas imágenes recae en el médico especialista en Radiología e Imagenología, quien analiza críticamente las imágenes, identifica patrones radiológicos anormales y emite un informe diagnóstico estructurado, y esto es una pieza de información clínica determinante para la estrategia terapéutica del médico tratante (Ministerio de Salud Pública del Ecuador, 2013).

2.2. Metodología de la investigación

Paradigma positivista

El paradigma de investigación que sigue este trabajo es la de positivista. Este paradigma también es conocido como empírico-analítico, es fundamentado en la creencia de que existe una realidad objetiva y medible, que se puede conocer por medio de la observación y de la experiencia (Hernández Sampieri & Fernández-Collado, 2014). Este paradigma quiere explicar, predecir y controlar fenómenos a través de identificar relaciones causa-efecto, mediante el uso de datos cuantitativos y el análisis estadístico para probar su hipótesis y establecer generalizaciones. Se centra en la objetividad, la capacidad de replicar resultados y la búsqueda de leyes o principios.

Enfoque mixto

Este enfoque se caracteriza por la utilización de técnicas estadística, matemática y computacionales que permitan la agrupación, análisis e interpretación de los datos para, a partir de ahí, buscar relaciones entre las variables, elaborar modelos predictivos y validar hipótesis a través de datos medibles y replicables (Hernández Sampieri & Fernández-Collado, 2014). El enfoque cuantitativo es, por tanto, el que resulta más útil para este proyecto, dado que se centra en el procesamiento y análisis de un gran número de datos extraídos de las radiografías del tórax, que

sirven luego para el aprendizaje de los modelos de aprendizaje automático, en particular de las redes neuronales convolucionales, cuyos resultados se evalúan mediante el uso de las métricas estadísticas como la precisión, la sensibilidad, la especificidad y el área bajo la curva ROC.

Métodos

En este proyecto se aplica una metodología que combina varios métodos científicos, tanto teóricos como empíricos, que ayudan a tratar el objeto de estudio de forma sistemática y rigurosa, es necesario que se apliquen estos métodos para tener una base científica en la investigación y aportar eficazmente al logro de los resultados propuestos.

Método analítico-sintético

Este método ayuda a dividir el problema de investigación, en sus partes constitutivos para poder estudiarlos de una forma específica para luego poder integrarlos y obtener una visión holística del fenómeno estudiado (Falcón & Serpa, 2021).

Método de modelación

Este método ayuda a representar de una manera simplificada la realidad estudiada, y establece relaciones entre sus elementos y cualidades. Por medio de la modelación, se logra estudiar todas las relaciones esenciales del objeto que se analiza, esto ayuda a su comprensión y posible transformación (Falcón & Serpa, 2021),

Análisis documental

Este método ayuda a la revisión crítica del material bibliográfico existente asociado con el tema de estudio, esto facilita la selección, la organización y el análisis de toda la información relevante para que se fundamente la investigación teóricamente

(Falcón & Serpa, 2021).

Tipo de investigación

Investigación aplicada

Esta investigación se relaciona con el tipo de investigación aplicada, que se enfoca a resolver problemas prácticos y proponer soluciones. Esto permite establecer una cercanía entre la teoría y la práctica, y esto habilita la aplicación de los conocimientos teóricos a ciertas situaciones específicas en el ámbito educacional (Falcón & Serpa, 2021)

Técnica e instrumento

La técnica de entrevista consta en un proceso de comunicación de forma verbal entre el investigador y el entrevistado, su objetivo es obtener información específica, adecuada y clara sobre un tema determinado (Hernández Sampieri & Fernández-Collado, 2014). Para esta investigación se eligió la entrevista estructurada, que es diseñada por el investigador, la cual tiene preguntas de tipo cerrada y opciones múltiples, esto permite cuantificar respuestas para su respectivo análisis.

Esta entrevista será aplicada a médicos en el área de clínica y especialistas en radiología de una institución universitaria privada, para poder saber cuál es su conocimiento del uso de inteligencia artificial en su área, la población de la investigación, un *dataset* con imágenes clínicas clasificadas, la muestra está conformada por médicos especialistas.

La población de la entrevista está constituida por alrededor de 35 médicos de una universidad privada, de esta población se seleccionó una muestra 5 médicos especialistas: 2 radiólogos y 3 médicos del área clínica.

Dimensión 1. Experiencia y procesos en el diagnóstico

- La interpretación de radiografías de tórax para el diagnóstico de neumonía es una tarea muy frecuente y primordial.
- La frecuencia de la interpretación de radiografías de tórax puede variar: ésta se puede realizar varias veces al día en hospitales frente a varias veces a la semana en zonas rurales.
- Existe un consenso sobre el potencial de error en la interpretación.
- El potencial de error es mayor en los casos más sutiles, en las radiografías de baja calidad o entre intérpretes menos experimentados.

Dimensión 2. Percepción sobre Sistemas de IA para Diagnóstico

- Los médicos tienen median familiaridad con la IA en diagnósticos por imágenes.
- Existe una idea positivista sobre el potencial de la IA para mejorar precisión y eficiencia.
- Su experiencia práctica con la IA es limitada.

Hay una preocupación significativa sobre:

- La fiabilidad de los algoritmos.
- La falta de interpretabilidad de los algoritmos.
- La responsabilidad legal en el uso de la IA.

Dimensión 3. Potencial Adopción y Uso de un Sistema de IA

- Se identifica una alta disposición a adoptar sistemas de IA validados y precisos.

Estos sistemas son vistos como herramientas para:

- Cribado.
- Apoyo en la toma de decisiones.

Existe el potencial de:

- Optimizar la carga de trabajo.
- Mejorar la calidad asistencial.

2.3. Metodología de desarrollo

Para el desarrollo de este proyecto, se decidió emplear la metodología ágil SCRUM, por su eficiencia en la gestión de proyectos tecnológicos que necesitan un enfoque iterativo e incremental, esta metodología ayuda a tener una organización flexible de todo el trabajo por medio de ciclos cortos de desarrollo llamados *sprints*, lo que hace más fácil la incorporación progresiva de funcionalidades, también la validación constante del producto y su adaptación a cambios en los requisitos. Dado que este proyecto involucra el desarrollo de un sistema automatizado de apoyo al diagnóstico de neumonía, con la combinación de varios componentes, SCRUM resulta adecuado al permitir una mejora continua por medio de retroalimentación.

Fases del proceso SCRUM:

1. Product Backlog.
2. Sprint Planning (Planificación del Sprint).
3. Sprint.
4. Daily Scrum (Reuniones diarias).
5. Sprint Review (Revision del Sprint).
6. Sprint Retrospective (Retrospectiva del Sprint).
7. Incremento.

1. *Product Backlog*

El *Product Backlog* es la forma de iniciar dicho proyecto. Es la lista que ordena todos los requerimientos, funcionalidades y tareas que el producto final debe incluir. Esta parte es clave en el contexto de nuestro proyecto, permite organizar y visualizar todo aquello que debemos tener en cuenta para construir el sistema final, desde la carga de imágenes hasta la predicción automática de neumonía.

Elementos del *Product Backlog*:

Carga y preprocesamiento de imágenes.

- Permitir al usuario cargar imágenes radiográficas desde el *frontend*.
- Preprocesar imágenes (escalado, normalización, cambio de tamaño) para el modelo.

Predicción con el Modelo

- Entrenamiento del modelo
- Integrar modelo entrenado para predicción de neumonía.
- Devolver probabilidad de neumonía para cada imagen cargada.

Backend API

- Crear *endpoints* para:
 - Subir imágenes.
 - Obtener predicción.
- Manejar errores y respuestas claras.

Frontend

- Interfaz para subir imágenes y mostrar resultados.
- Visualizar imagen original
- Mostrar mensajes de éxito/error.

Entrenamiento del Modelo CNN

- Entrenar el modelo con el uso del *dataset* de imágenes.
- Obtener métricas de la evaluación del modelo.

Documentación y Usabilidad

- Documentar cómo usar la API y el *frontend*.
- Instrucciones para instalar dependencias y ejecutar el sistema.

Validación del sistema.

- Probar el modelo con imágenes no vistas.
- Revisar tasa de falsos positivos y falsos negativos.

2. Sprint Planning (Planificación del Sprint)

En esta etapa se revisa el producto backlog y se seleccionan los elementos más prioritarios para el primer *sprint*. El objetivo principal de este primer sprint es tener un sistema funcional mínimo que permita subir imágenes, procesarlas y que el modelo entrenado dé una predicción.

Objetivo del Sprint 1

Desarrollar un sistema funcional básico que le permita al usuario subir una imagen radiográfica, que esta la procese e identifique si existe probabilidad de neumonía y que devuelva un resultado en la interfaz de usuario (*frontend*).

Tareas seleccionadas del backlog para el Sprint

Elementos	Subtareas	Estimación(días)
1.Carga y procesamiento de imágenes	-Cargar imágenes desde la interfaz de usuario -Preprocesar imágenes (escalado, normalización)	3
2.Predicción con el modelo	-Entrenar modelo -Integrara modelo entrenado	5
3.Parte del servidor (Backend) Api	-Crear punto de acceso para subir imágenes -Crear punto de acceso para obtener la predicción -Manejar errores	3
4.Interfaz de Usuario Básico	-Interfaz para subir imágenes -Mostrar resultado de predicción -Mostrar mensaje de error	2

3. Sprint

En esta fase, se implementan las funcionalidades priorizadas en el primer *sprint*, de acuerdo con lo que se define en el *Sprint Planning*. El objetivo es alcanzar una versión funcional mínima.

Duración del Sprint

- 2 semana (14 días hábiles)

Actividades realizadas

Carga y procesamiento de imágenes

- Se implementó un componente en la interfaz de usuario que permite seleccionar y subir una imagen radiográfica desde el equipo del usuario.
- Las imágenes son procesadas automáticamente en la parte del servidor: se ajustó su tamaño a (256,256 px), se le convierte a escala de grises si es necesario, y se normalizan los valores de los píxeles a 0 y 1 para que coincidan con las características con las cuales el modelo fue entrenado.

Predicción con el modelo

- Entrenar el modelo CNN.
- Se carga el modelo entrenado con ayuda de TensorFlow/Keras.
- Una vez el modelo recibe la imagen procesada, el modelo realiza una predicción con la probabilidad de que la imagen represente un caso de neumonía.
- La predicción es devuelta en formato JSON, con la indicación del nivel de confianza del modelo.

Desarrollo de la parte del servidor (Backend API)

- Se implemento un servidor con la ayuda de FastApi para gestionar las solicitudes del sistema
- Se creo un punto de acceso que recibe una la imagen del usuario, predice con el modelo la probabilidad de neumonía y la devuelve en formato Json.

Desarrollo de la interfaz de usuario (Frontend)


Se creo una interfaz simple con el uso de React que permite al usuario:

- Subir imágenes radiográficas.
- Ver la imagen cargada.
- Visualizar el resultado de la predicción.
- Recibir mensajes de error o confirmación.

Pruebas unitarias básicas

- Validación de formato y tipo de imagen.
 - Precisión (Accuracy): 87.50%
 - Área bajo la curva (AUC): 93.75%
 - Pérdida (Loss): 0.3313

Figura 1. Evaluación del modelo.

```
1/1  6s 6s/step - accuracy: 0.8750 - auc: 0.9375 - loss: 0.3313  
Test Accuracy: 0.8750, AUC: 0.9375
```

Fuente: elaboración propia

- Verificación de la respuesta de la API.
- Verificación del correcto procesamiento.

Resultado del Sprint

- El sistema le permite al usuario subir imágenes, procesarlas y obtener predicciones correctamente.
- La comunicación entre la interfaz de usuario y la parte del servidor.
- La interfaz le ofrece al usuario una experiencia básica pero funcional.

4. *Daily Scrum* (Reuniones diarias)

El *daily scrum* donde se comparte el estado actual de las tareas asignadas, se perciben las barreras y se planifica el trabajo del día.

Objetivos del Daily Scrum

- Revisar el avance hacia el objetivo del Sprint.
- Coordinar esfuerzos diarios.
- Identificar bloqueos o necesidades técnicas.
- Mantener visibilidad y responsabilidad personal.

Implementación en el proyecto

En el contexto de este proyecto de tesis, donde el equipo puede estar conformado por una o dos personas, se optó por registrar los Daily Scrum como un diario técnico o bitácora de avances. Esto permitió:

- Mantener una trazabilidad del trabajo realizado.
- Detectar rápidamente tareas que utilizaban más tiempo de lo estimado.
- Redirigir esfuerzos si una fase crítica (como la integración del modelo) se detenía por un error técnico.

5. Sprint Review (Revision del sprint)

El sprint *review* es una reunión que se lleva a cabo cuando se finaliza un Sprint. El objetivo es examinar todo lo desarrollado y adaptar el *product backlog* si es necesario. Se muestra lo realizado para recibir una retroalimentación de los involucrados.

Durante el sprint *review* del sistema creado se presentó un prototipo funcional con las siguientes características:

Funcionalidades completadas en el sprint:

1. Entrenamiento del modelo.
2. Carga y visualizaciones en la interfaz de usuario.
3. Preprocesamiento (reescaldado y normalización) en la parte del servidor.
4. Predicción con el modelo ya entrenado.
5. Envío de la respuesta del modelo en formato Json,
6. Interfaz de usuario que muestra la imagen cargada, resultado de la predicción.

A continuación, se detallarán cada proceso como fue realizado:

- **Entrenamiento del modelo**

Su desarrollo fue realizado en el entorno de Google Colab, con el uso TensorFlow y comprendido con los siguientes pasos:

1. Adquisición y preparación de Datos:

- Se obtuvieron los datos de la plataforma Kaggle, específicamente el conjunto llamado *chest-xray-pneumonia*.
- Se configuro las credenciales de Kaggle en el entorno para facilitar su descarga.

Figura 2. Código para la descarga del *dataset*.

```
#Descargar el datase desde kaggle
!kaggle datasets download -d paultimothymooney/chest-xray-pneumonia

Dataset URL: https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia
License(s): other
```

Fuente: elaboración propia

- Se extrajo el archivo Zip en el directorio local.

Figura 3. Código para descomprimir el *dataset*.

```
[ ] #Extraer el archivo zip
!unzip chest-xray-pneumonia.zip -d ./data

Se truncaron las últimas líneas 5000 del resultado de transmisión.
```

Fuente: elaboración propia

2. Visualización Exploratorio de Datos:

- Se implemento una función que permite la visualización de imágenes aleatorias pertenecientes a clases 'Normal' y 'Neumonía'.

3. Procesamiento y Aumento de Datos:

- Se estableció las rutas de directorios de entrenamiento (*train*), prueba (*test*) y validación(*val*).

Figura 4. Código para definir la ruta de directorios.

```
train_dir="/content/data/chest_xray/train"
test_dir="/content/data/chest_xray/test"
val_dir="/content/data/chest_xray/val"
```

Fuente: elaboración propia

- Se uso el generador de Imágenes de Keras (*ImageDataGenerator*) que sirvió para:

Figura 5. Código para importar librería.

```
from tensorflow.keras.preprocessing.image import ImageDataGenerator
```

Fuente: elaboración propia

- Reescalar los valores de los píxeles al rango de [0,1].
- Carga de imágenes por lotes (*batches*) para que el procesamiento sea eficiente.
- Se aplicaron técnicas de aumento de datos (*data augmentation*) al conjunto de entrenamiento, para mejorar la capacidad de generalización del modelo. Los cambios incluyeron rotación, zoom, desplazamiento horizontal/vertical, ajustes de brillo y volteo horizontal.

Figura 6. Código para implementar *data augmentation* a nuestros datos.

```
train_datagen_augmented = ImageDataGenerator(rescale=1/255.,
                                             rotation_range=15,
                                             shear_range=0.1,
                                             zoom_range=0.2,
                                             width_shift_range=0.1,
                                             height_shift_range=0.1,
                                             fill_mode='nearest',
                                             brightness_range=[0.8, 1.2],
                                             horizontal_flip=True)
```

Fuente: elaboración propia

- Definir el tamaño objetivo de las imágenes (224x224 px) y el modo de color (escala de grises).

Figura 7. Código para preparar un flujo de datos de entrenamiento aumentado.

```
train_data_augmented = train_datagen_augmented.flow_from_directory(train_dir,
                                                                    class_mode="binary",
                                                                    target_size=(224,224),
                                                                    shuffle=True,
                                                                    color_mode='grayscale')
```

Fuente: elaboración propia

4. Diseño y Compilación del Modelo:

- Se construyó una Red Neuronal Convolutiva, se usó la Api *Sequential* de Keras.

Figura 8. Código para importar *Sequential*

```
from tensorflow.keras import Sequential
```

Fuente: elaboración propia

- La arquitectura del modelo se estructura de la siguiente manera:
 - Múltiples capas convolucionales (*Conv2D*) con una función de activación ReLU (Unidad Lineal Rectificada).
 - Capas de agrupación Máxima (*MaxPool2D*) para la reducción de la dimensionalidad espacial y la complejidad computacional.

Figura 9. Código de una capa densa del modelo.

```
# Primera capa convolucional: 32 filtros de 3x3, activación ReLU
Conv2D(32, (3, 3), activation='relu', input_shape=(224, 224, 1)),
BatchNormalization(),# Normaliza la activación de la capa anterior, acelera el entrenamiento y mejora estabilidad
MaxPool2D(pool_size=2),# Reduce dimensionalidad manteniendo características principales (pooling 2x2)
```

Fuente: elaboración propia

- Una capa de aplanamiento (*Flatten*) para transformar las salidas en un vector unidimensional.
- Una capa Densa (*Dense*) con activación ReLU.
- Una capa de Regularización por Abandono (*Dropout*) para mitigar el sobre ajuste (cuando el modelo se vuelve muy específico para los datos de entrenamiento).

Figura 10. Código que prepara y procesa la información de la red neuronal.

```
Flatten(),# Aplanamos las salidas para pasar a la capa densa
Dense(128, activation='relu'), # Capa totalmente conectada con 128 neuronas y activación ReLU
Dropout(0.5),# Dropout del 50% para prevenir overfitting
```

Fuente: elaboración propia

- Una capa Densa de salida con una única neurona y una función de activación sigmoide, para su clasificación binaria.

Figura 11. Código capa de salida para clasificación binaria.

```
# Capa de salida: 1 neurona con activación sigmoide (para clasificación binaria)
Dense(1, activation='sigmoid')
```

Fuente: elaboración propia

- La compilación del modelo se realizó con las siguientes especificaciones:
 - La función de pérdida '*binary_crossentropy*' que es usada para problemas de clasificación binaria.
 - El optimizador Adam, con una tasa de aprendizaje del 1e-4.
 - Las métricas de '*accuracy*' (precisión) y AUC (Área Bajo la Curva Roc) para monitorear el rendimiento del modelo durante el entrenamiento y la evaluación.

Figura 12. Código compilación del modelo

```
#Compilamos el modelo
modelo.compile(loss="binary_crossentropy",
               optimizer=Adam(learning_rate=1e-4),
               metrics=['accuracy', tf.keras.metrics.AUC()])
```

Fuente: elaboración propia

5. Entrenamiento del Modelo:

- El modelo se entrenó con el uso del método *fit()*, llenándolo con los datos de
- entrenamiento
- Se define un numero de épocas (*epochs=15*).
- Se utilizaron los datos de prueba (*test_data*) para validación durante el
- entrenamiento, esto permite monitorear el desempeño del modelo con datos no vistos.

Figura 13. Código entrenamiento del modelo

```
history = modelo.fit(
    train_data_augmented,
    validation_data=test_data,
    epochs=15,
    steps_per_epoch=len(train_data_augmented),
    validation_steps=len(test_data),
    verbose=1
)
```

Fuente: elaboración propia

6. Evaluación del modelo

- El modelo entrenado se evaluó sobre el conjunto de evaluación (*val_data*).
- Esta evaluación brinda métricas de rendimiento tales como la pérdida, la precisión.

Figura 14. Código evaluación del modelo

```
#Evaluacion del modelo
val_evaluation = val_datagen.flow_from_directory(
    '/content/data/chest_xray/val',
    target_size=(224, 224),
    batch_size=32,
    class_mode='binary',
    color_mode='grayscale'
)

loss, acc, auc = modelo.evaluate(val_evaluation)
print(f"Test Accuracy: {acc:.4f}, AUC: {auc:.4f}")
```

Fuente: elaboración propia

Figura 15. Evaluación del modelo.

```
1/1 ————— 6s 6s/step - accuracy: 0.8750 - auc: 0.9375 - loss: 0.3313
Test Accuracy: 0.8750, AUC: 0.9375
```

Fuente: elaboración propia

En mayor detalle se explica en el capítulo 3.

7. Persistencia del Modelo

- El modelo se guardó en Google drive en formato HDF5 (.h5) para descargarlo e implementarlo en nuestro sistema.
- **Carga y visualización en la interfaz de la aplicación**

Se implementó una interfaz de la aplicación a partir de *React* que permite a los usuarios cargar imágenes y visualizar tanto la imagen cargada como los resultados que obtuvieron tras analizar la imagen. Los componentes usados son:

1. Componente de carga de imágenes (ImageUpload.js)

Permite a los usuarios seleccionar una imagen desde un dispositivo y enviarla hacia la parte del servidor, y este realizara su predicción. También permite visualizar la imagen seleccionada, mostrando así una vista previa de la imagen cargada.

Principales características

- Se valida el tipo del archivo para verificar que es una imagen.
- Vista previa de la imagen cargada.
- Envío de la imagen a la parte del servidor.

La evidencia se encuentra en el Anexo2

- **Preprocesamiento (reescaldado y normalización) en la parte del servidor.**

En el servidor, se implementó un proceso de preprocesamiento para preparar las imágenes antes de enviarlas al modelo. A continuación, se enumeran las etapas del preprocesamiento:

1. Conversión en escala de grises

Dado que el modelo fue entrenado con imágenes en escala de grises, es fundamental llevar a cabo la conversión de todas las imágenes a este modo.

2. Redimensión de la imagen

La imagen se redimensiona a un tamaño de 224x224 pixeles, que es el tamaño que se espera por parte del modelo.

3. Normalización de los valores de los píxeles

Los valores de los píxeles se normalizan entre el rango [0,1], se divide cada valor entre 255, lo cual asegura que los datos de entrada sean consistentes con los datos con que fue entrenado el modelo.

Figura 16. Código para procesar imagen subida por el usuario.

```

1 def preprocess_image(image_bytes):
2     try:
3         # Convertir bytes a imagen
4         image = Image.open(io.BytesIO(image_bytes))
5         # Convertir a escala de grises si es necesario
6         if image.mode != 'L': # 'L' indica escala de grises
7             image = image.convert('L')
8         # Redimensionar la imagen a 224x224 píxeles
9         image = image.resize((224, 224))
10        # Convertir a array y normalizar los valores de los píxeles
11        image_array = np.array(image) / 255.0
12        # Añadir dimensiones para que sea compatible con el modelo
13        image_array = np.expand_dims(image_array, axis=-1) # Añadir canal para escala de grises
14        image_array = np.expand_dims(image_array, axis=0) # Añadir dimensión de batch
15        return image_array
16    except Exception as e:
17        raise HTTPException(status_code=400, detail=f"Error al procesar la imagen: {str(e)}")

```

Fuente: elaboración propia

- **Predicción con el modelo ya entrenado.**

En la parte del servidor se implementó un punto de acceso para realizar predicciones con ayuda del modelo.

1. Cargar el modelo

El modelo entrenado se carga al iniciar el servidor.

Figura 17. Código para cargar el modelo.

```

1 try:
2     model = tf.keras.models.load_model("modelo_neumonia.h5")
3 except Exception as e:
4     print(f"Error loading model: {e}")
5     model = None

```

Fuente: elaboración propia

2. Recepción de la imagen

El servidor recibe la imagen enviada por el usuario.

Figura 18. Función de predicción de imagen.

```
@app.post("/predict")
async def predict(file: UploadFile = File(...)):
    if not model:
        raise HTTPException(status_code=500, detail="Model not loaded")

    try:
        # Verificar el tipo de archivo
        if not file.content_type.startswith('image/'):
            raise HTTPException(status_code=400, detail="El archivo debe ser una imagen")

        # Leer la imagen
        contents = await file.read()

        # Preprocesar la imagen
        image = preprocess_image(contents)
```

Fuente: elaboración propia

3. Predicción con el modelo

La imagen preprocesada se la pasa al modelo para realizar la predicción, el modelo devuelve una probabilidad que indica la posibilidad de que la imagen corresponda a un caso de neumonía.

Figura 19. Obtención y evaluación de la predicción del modelo.

```
1 # Realizar predicción
2 prediction = model.predict(image)
3
4 # Obtener resultado
5 probability = float(prediction[0][0])
6 diagnosis = "PNEUMONIA" if probability > 0.5 else "NORMAL"
```

Fuente: elaboración propia

- **Envío de la respuesta del modelo en formato Json**

El resultado de la predicción se devuelve al usuario en formato JSON.

Figura 20. Retorno de resultado y manejo de errores.

```

return {
    "diagnosis": diagnosis,
    "probability": probability,
    "timestamp": str(tf.timestamp())
}
except Exception as e:
    raise HTTPException(status_code=500, detail=str(e))

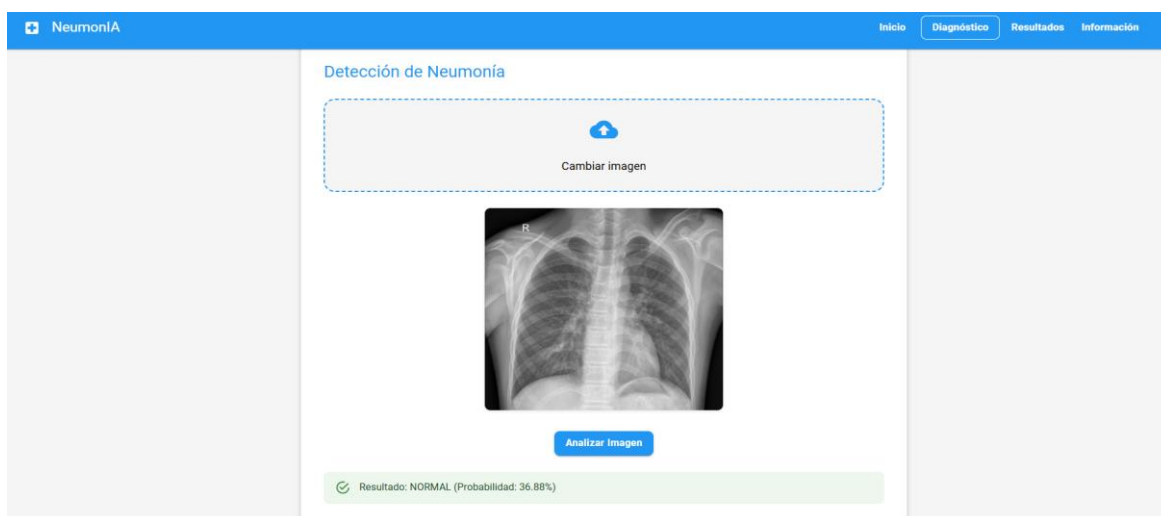
```

Fuente: elaboración propia

- **Interfaz de usuario que muestra la imagen cargada, resultado de la predicción.**

En el proyecto se desarrolló una interfaz que permite al usuario cargar una imagen radiográfica, enviarla a la parte del servidor para su análisis y mostrar la predicción.

Figura 21. Interfaz de usuario para cargar imágenes.



Fuente: elaboración propia

Retroalimentación recibida

Se mostro el sistema a usuarios simulados y se obtuvo la siguiente retroalimentación:

- Positiva: Valoraron la facilidad de uso
- Sugerencias:
- Mejorar la interfaz de usuario.

Con esta retroalimentación se actualiza el *product backlog* para próximos *sprints*, la revisión del sprint permitió garantizar que el sistema va en la dirección correcta, para cumplir con varias funcionalidades claves.

6. Sprint Retrospective (Retrospectiva del *Sprint*)

El *Sprint Retrospective* es una reunión interna que se realiza al acabar un sprint, después del *Sprint Review*. Su funcionalidad es identificar que funciona bien, que es lo que se puede mejorar y proponer formas de incrementar la eficiencia.

En el sprint retrospective se analizó el desarrollo del primer prototipo, y se identificaron aspectos positivos.

Aspectos positivos:

- **Buena planificación inicial:** El producto backlog fue claro y bien priorizado, esto permitió una buena organización de tiempo.
- **Integración fluida entre la interfaz de usuario y la parte del servidor:** Las funcionalidades propuestas lograron conectarse sin problemas.

La metodología Scrum favoreció la progresión de un sistema básico funcional para el diagnóstico de la neumonía. La planificación inicial se formuló de forma precisa, el producto backlog se definió de forma clara y ayudó a organizar el trabajo. Además, la integración de la interfaz de usuario y la parte de servidor fue fluida, pues se aprovecharon métodos para el procesamiento y la predicción de imágenes de forma conveniente. También es un buen logro el entrenamiento del modelo CNN con buena precisión y AUC más la programación de la interfaz de usuario funcional. Por otro lado, la retrospectiva también evidenció áreas de mejora: la principal recomendación expuesta fue la necesidad de mejorar la interfaz de usuario. Esta recomendación es posible de incluir en el producto backlog para sprints futuros. Finalmente, el proceso Scrum condujo a una iteración y validación del producto que es clave para el desarrollo de un sistema.

CAPÍTULO III. ANÁLISIS DE LOS RESULTADOS DE LA INVESTIGACIÓN

En este capítulo se dedica al análisis de los resultados obtenidos tras la evaluación del modelo. Se mostrarán las métricas de rendimiento alcanzadas por el modelo sobre el conjunto de validación.

3.1. Validación del modelo

Una vez completado el proceso de entrenamiento se realizó una evaluación de su rendimiento de su rendimiento. Esta evaluación se la realizo con el uso del conjunto de datos de validación, el cual contiene imágenes que el modelo no había encontrado anteriormente en la fase de entrenamiento. Esto garantiza una comprobación objetiva la capacidad de generalización del modelo.

Para cuantificar el rendimiento del clasificador binario (Normal vs Neumonía) se usaron diversas métricas que se consideran estándar en el área de aprendizaje automático, y como método de evaluación de modelos de diagnóstico por imagen. Las métricas que a continuación se describen, son las que se usaron:

Obtención de predicciones y etiquetas verdaderas:

Antes de calcular las métricas, lo primero que tuvo que hacerse fue extraer las predicciones del modelo para todas las imágenes del conjunto de evaluación a fin de compararlas con las respectivas etiquetas verdaderas.

Primero, se extrajeron las etiquetas de (*val_labels*), luego se usó el método *predict()* del modelo entrenado sobre el conjunto de datos de validación. El método *predict* pertenece a la librería de *scikit-learn* es usado para generar predicciones en nuevos datos con el uso del modelo entrenado.

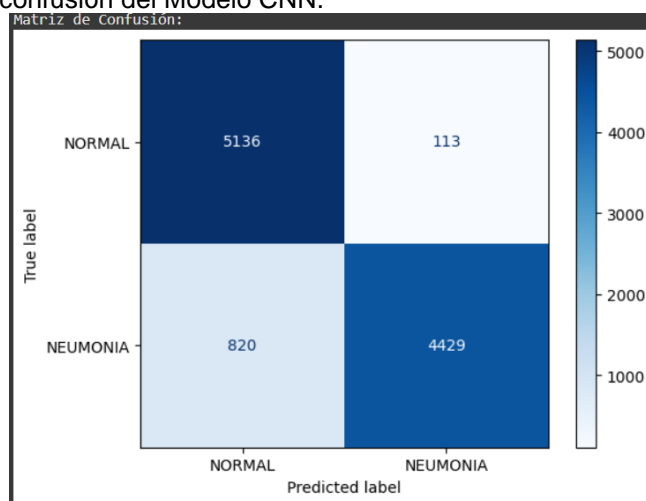
Matriz de Confusión

La matriz de confusión es una herramienta que permite visualizar el desempeño de un algoritmo de clasificación. Por medio de una tabla donde cada fila representa las instancias en una clase real y cada columna representa las instancias de una clase predicha, además la matriz de confusión muestra:

- **Verdadero Positivos (VP):** Casos de neumonía identificados correctamente como neumonía.
- **Verdaderos Negativos (VN):** Casos normales identificados correctamente como normales.
- **Falsos Positivos (FP) o Error Tipo I:** Casos normales identificados incorrectamente como neumonía.
- **Falsos Negativos (FN) o Error Tipo II:** Casos de neumonía identificados incorrectamente como normales.

La matriz de confusión se construyó utilizando la función *confusion_matrix* de la librería *scikit-learn*, con el propósito de comparar las etiquetas verdaderas y la respectiva predicción obtenida por el modelo. Para una mejor interpretación se lo visualizó gráficamente con el uso de *ConfusionMatrixDisplay*. El análisis de la matriz de confusión es esencial para poder identificar el balance entre Falsos Positivos y Falsos Negativos, que pueden tener distintas implicaciones en el contexto clínico.

Figura 22. Matriz de confusión del Modelo CNN.



Fuente: elaboración propia

Esta matriz visualiza la capacidad del modelo para clasificar entre las clases 'Normal' y 'Neumonía'. Se observa que el modelo clasificó un número considerable de imágenes: 5136 radiografías fueron correctamente identificadas como 'Normal' (Verdaderos Negativos) y 4492 radiografías que fueron correctamente identificadas como 'Neumonía' (Verdaderos Positivos). También se produjeron errores de clasificación, específicamente 113 casos 'Normales' fueron incorrectamente clasificados como 'Neumonía' (Falsos Positivos) y 820 casos de 'Neumonía' fueron clasificados como 'Normal' (Falsos Negativos).

Reporte de clasificación

El reporte de clasificación fue generado mediante la función *classification_report* de *scikit-learn*, proporciona un resumen de las principales métricas de clasificación para cada clase. Estas métricas incluyen:

- **Precisión (Precisión):** Mide la proporción de identificaciones positivas que fueron realmente correctas. Una alta precisión indica que en los casos que el modelo predice neumonía, es muy probable que sea correcto. Se calcula como (Google Developers, s. f.)

$$Precision = \frac{VP}{VP + FP}$$

- **Sensibilidad (*Recall* o *Exhaustividad*):** Mide la proporción de positivos reales que fueron correctamente identificados, una alta sensibilidad es crítica, indica que el modelo es bueno para detectar la mayoría de casos reales de neumonía. Se calcula como (Google Developers, s.f.):

$$Recall = \frac{VP}{VP + FN}$$

- **Puntuación F1(F1-Score):** Es la media armónica entre la sensibilidad y la precisión. Es útil cuando se busca un balance entre no alarmar innecesariamente (evitar FP) y no pasar por alto casos positivos (FN). Se calcula como (Google Developers, s.f.):

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

Este reporte brinda una evaluación detallada del rendimiento del modelo para cada clase.

Figura 23. Reporte de clasificación del Modelo CNN.

Reporte de Clasificación:				
	precision	recall	f1-score	support
NORMAL	0.86	0.98	0.92	5249
NEUMONIA	0.98	0.84	0.90	5249
accuracy			0.91	10498
macro avg	0.92	0.91	0.91	10498
weighted avg	0.92	0.91	0.91	10498

Fuente: elaboración propia

Para la clase Normal el modelo alcanzó una precisión de 0.86 y una sensibilidad (*recall*) de 0.98, con una puntuación F1 de 0.92. Esto indica que el modelo es muy efectivo en identificar casos que son genuinamente normales, cuando predice 'Normal' es generalmente correcto en el 86% de los casos. En cuanto a la clase 'Neumonía' se puede observar una alta precisión de 98%, esto significa que cuando el modelo diagnostica 'Neumonía' es altamente probable que esa predicción sea correcta, sin embargo, la sensibilidad (*recall*) es de 0.84, lo que indica que el modelo

solo pudo identificar el 84% de todos los casos de neumonía. La puntuación F1 para 'Neumonía' fue de 0.90, la exactitud(*accuracy*) fue del 91%, esto da un promedio para las tres métricas principales de 0.91, esto refleja un rendimiento global robusto y equilibrado.

Curva ROC (Receiver Operating Characteristic) y AUC (Area Under the Curve)

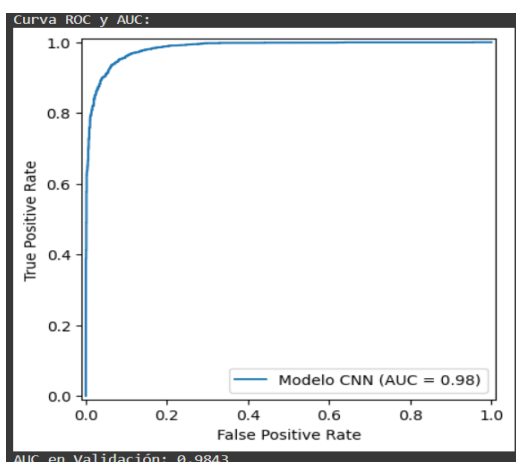
La curva ROC es una representación gráfica del como rinde el clasificador binario a medida que se varía el umbral de discriminación. Grafica en el eje Y la sensibilidad (tasa de verdaderos positivos) y en el eje X la especificidad (tasa de falsos positivos).

- **Tasa de falsos positivos (FPR):** Proporción de negativos reales que fueron incorrectamente clasificados como positivos.
- **Especificidad:** Proporción de negativos reales que fueron que fueron correctamente identificados.

El área bajo la curva (AUC) es una métrica que resume el rendimiento de la curva ROC. Un AUC de un 1.0 significa correctamente clasificar todos los positivos y negativos. Mientras que un AUC de un 0.5 significa que el modelo sólo puede hacer clasificaciones aleatorias, lo que no le hace mejor que simplemente lanzar una moneda al aire.

Con la finalidad de generar la curva y, luego, poder calcular el AUC, se utilizó la biblioteca scikit-learn, en la que se usaron las etiquetas verdaderas junto con las probabilidades de predicción generadas por el modelo, aplicando algorítmicamente las funciones `roc_curve` de dicha biblioteca. La visualización se realizó con *RocCurveDisplay*.

Figura 24. Curva ROC y AUC del Modelo CNN.



Fuente: elaboración propia

Se observa que la curva asciende de forma rápida hacia la esquina superior izquierda del gráfico, esto significa un alto rendimiento en la distinción entre las clases 'Normal' y 'Neumonía'. El Área Bajo la Curva (AUC) fue de 0.98, este valor es muy cercano a 1 y resalta la excelente capacidad del modelo para clasificar correctamente las imágenes.

Métricas globales del modelo

Además de las métricas anteriores, se utilizaron los resultados directos proporcionados por el método *evaluate()* de keras sobre el conjunto de validación.

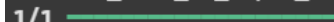
Esto devuelve:

- **Perdida (Loss):** El valor de la función de pérdida indica cuán bien o mal el modelo se está desempeñando en términos del objetivo de optimización.
- **Exactitud (Accuracy):** El tamaño de predicciones correctas sobre el total de muestra en el conjunto de validación. Se calcula como (Google Developers, s.f.):

$$Accuracy = \frac{VP + VN}{VP + VN + FP + FN}$$

- **AUC (Métricas del modelo):** Tensorflow también puede calcular una métrica de AUC durante la etapa de evaluación.

Figura 25. Evaluación del Modelo CNN.

```
1/1  6s 6s/step - accuracy: 0.8750 - auc: 0.9375 - loss: 0.3313  
Test Accuracy: 0.8750, AUC: 0.9375
```

Fuente: elaboración propia

CONCLUSIONES

- El análisis del estado del arte señala el hecho de que las CNN son una herramienta de primer orden para la clasificación de imágenes y se puso de manifiesto su capacidad para extraer características significativas de las imágenes debido a la utilización de capas convolucionales. Se constató la importancia de las técnicas de preprocesamiento en los datos y el aumento de dato (*data augmentation*) para la generalización del modelo. De igual manera se encontró la necesidad de evaluar la efectividad del modelo, con el uso métricas como la sensibilidad, especificidad y precisión.
- Se obtuvo el conjunto de datos “Chest X-Ray Images (Pneumonia)” desde la plataforma de Kaggle, la cual proporciono una gran cantidad de radiografías del tórax ya etiquetadas como “Normal” o “Neumonía”, se crearon los procedimientos necesarios para la descarga, extracción y organización del *dataset*, lo cual fue clave para su desarrollo y evaluación.
- Se creó una Red Neuronal Convolucional, personalizada, cuyo diseño es acorde a la tarea de clasificación binaria de imágenes (imágenes de tórax de 224x224 píxeles en escala de grises), la arquitectura del modelo consta de tres capas convolucionales: la primera de 32 filtros (3x3, de activación ReLU), la segunda con 64 filtros (3x3, ReLU) y la tercera con 128 filtros (3x3, ReLU), cada capa seguida de un *BatchNormalization* para acelerar y estabilizar el rendimiento y de una capa de MaxPool2D para reducir la dimensionalidad. Después de las capas convolucionales se implementó una capa *Flatten*, seguida de una capa Dense con 128 neuronas, y una capa Dense de salida de una neurona y activación sigmoide para la clasificación. La efectividad de este modelo alcanzo una exactitud de 91%, un Área Bajo la Curva Roc (AUC) de 0.98 y una puntuación F1 de 0.9 lo que demuestra su capacidad para la tarea propuesta.

RECOMENDACIONES

- Investigar el rendimiento de arquitecturas como Vision Transformer (ViT), Swin Transformer, Data-efficient Image Transformer (DeiT) para la clasificación de imágenes por tórax.
- Establecer colaboraciones con instituciones médicas para acceder a *datasets* más extensos, incluyendo diferentes tipos de rayos X y las poblaciones demográficas correspondientes.
- Incluir funcionalidades de localización visual de las áreas de interés patológicos. Implementar técnicas como *Class Activation Maps* o algunas de sus variantes (Grad-CAM, Grad-Cam++)

BIBLIOGRAFÍA

- Ai, K., Ji, S., & Mm, B. (2020). CoroNet: A deep neural network for detection and diagnosis of COVID-19 from chest x-ray images. *PubMed*. Recuperado de <https://pubmed.ncbi.nlm.nih.gov/32534344/>
- CIDS, C. de I. y D. de S. (2021, enero). Editorial Unimagdalena. Recuperado 18 de julio de 2025, de <https://editorial.unimagdalena.edu.co/>
- Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K., ... Dean, J. (2019). A guide to deep learning in healthcare. *Nature Medicine*, 25(1), 24-29. <https://doi.org/10.1038/s41591-018-0316-z>
- Falcón, A. L., & Serpa, G. R. (2021). Acerca de los métodos teóricos y empíricos de investigación: Significación para la investigación educativa. *Revista Conrado*, 17(S3), 22-31.
- Goodfellow, Bengio, & Courville. (2016). Deep Learning. MIT Press. Recuperado 18 de julio de 2025, de MIT Press website: <https://mitpress.mit.edu/9780262035613/deep-learning/>
- Google Developers. (s. f.). Clasificación: Exactitud, recuperación, precisión y métricas relacionadas | Machine Learning. Recuperado 18 de julio de 2025, de Google for Developers website: <https://developers.google.com/machine-learning/crash-course/classification/accuracy-precision-recall?hl=es-419>
- Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., ... Webster, D. R. (2016). Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. *JAMA*, 316(22), 2402-2410. <https://doi.org/10.1001/jama.2016.17216>

- Hammad, M. M. (2024, julio 27). *Comprehensive Survey of Complex-Valued Neural Networks: Insights into Backpropagation and Activation Functions*. arXiv. <https://doi.org/10.48550/arXiv.2407.19258>
- Hernández Sampieri, R., & Fernández-Collado, C. F. (2014). *Metodología de la investigación* (Sexta edición; P. Baptista Lucio, Ed.). México D.F.: McGraw-Hill Education.
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70-90. <https://doi.org/10.1016/j.compag.2018.02.016>
- Krizhevsky, A., Sutskever, I., & Hinton, G. (2017). ImageNet classification with deep convolutional neural networks | Communications of the ACM. Recuperado 18 de julio de 2025, de <https://dl.acm.org/doi/10.1145/3065386>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/10.1038/nature14539>
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88. <https://doi.org/10.1016/j.media.2017.07.005>
- McKinney, S. M., Sieniek, M., Godbole, V., Godwin, J., Antropova, N., Ashrafian, H., ... Shetty, S. (2020). International evaluation of an AI system for breast cancer screening. *Nature*, 577(7788), 89-94. <https://doi.org/10.1038/s41586-019-1799-6>
- Ministerio de Salud Pública del Ecuador. (2013). Ministerio de Salud Pública – El Ministerio de Salud Pública ejerce la rectoría del Sistema Nacional de Salud a fin de garantizar el derecho a la salud del pueblo ecuatoriano. Recuperado 18 de julio de 2025, de <https://www.salud.gob.ec/>

- Molina. (s. f.). Redes neuronales artificiales: Fundamentos y aplicaciones. Recuperado 18 de julio de 2025, de <https://evidenciasenpediatria.es/articulo/8518/redes-neuronales-artificiales-fundamentos-y-aplicaciones>
- Nair, V., & Hinton, G. E. (2010). *Rectified Linear Units Improve Restricted Boltzmann Machines*.
- Nusrat, I., & Jang, S.-B. (2018). A Comparison of Regularization Techniques in Deep Neural Networks. *Symmetry*, 10(11), 648. <https://doi.org/10.3390/sym10110648>
- Obermeyer, Z., Powers, B., Vogeli, C., & Mullainathan, S. (2019). Dissecting racial bias in an algorithm used to manage the health of populations. *Science*, 366(6464), 447-453. <https://doi.org/10.1126/science.aax2342>
- OPS. (2012). OPS/OMS | Organización Panamericana de la Salud. Recuperado 18 de julio de 2025, de <https://www.paho.org/es>
- Ordoñez, O., & Andrés, M. (2008). *Diseño, entrenamiento e implementación de una red neuronal artificial en una aplicación de comprensión de voz* (bachelorThesis, QUITO/ EPN/ 2008). QUITO/ EPN/ 2008. Recuperado de <https://bibdigital.epn.edu.ec/handle/15000/843>
- Rajpurkar, P., Irvin, J., Ball, R. L., Zhu, K., Yang, B., Mehta, H., ... Lungren, M. P. (2018). *Deep learning for chest radiograph diagnosis: A retrospective comparison of the CheXNeXt algorithm to practicing radiologists*. <https://doi.org/10.1371/journal.pmed.1002686>
- Rivas Asanza, W., & Mazón Olivo, B. (2018). *Redes neuronales artificiales aplicadas al reconocimiento de patrones*. Machala : Universidad Técnica de Machala. Recuperado de <https://repositorio.utmachala.edu.ec/handle/48000/12499>

- Ronneberger, O., Fischer, P., & Brox, T. (2015, noviembre 18). *U-Net: Convolutional Networks for Biomedical Image Segmentation*. https://doi.org/10.1007/978-3-319-24574-4_28
- Samek, W., Wiegand, T., & Müller, K.-R. (2017, agosto 28). *Explainable Artificial Intelligence: Understanding, Visualizing and Interpreting Deep Learning Models*. arXiv. <https://doi.org/10.48550/arXiv.1708.08296>
- Schneider, J. (2024, abril 15). *Explainable Generative AI (GenXAI): A Survey, Conceptualization, and Research Agenda*. arXiv. <https://doi.org/10.48550/arXiv.2404.09554>
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2019). Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization. *International Journal of Computer Vision*, 128(2), 336-359. <https://doi.org/10.1007/s11263-019-01228-7>
- Silva. (2022). Evaluación del uso de redes neuronales artificiales en la predicción de resultados de un proceso de isomerización para su uso como herramienta didáctica en la materia de simulación de procesos. Recuperado 18 de julio de 2025, de <https://dspace.esPOCH.edu.ec/items/c32aa7f6-b2c2-4135-a858-37a9ef176308>
- Topol, E. J. (2019). High-performance medicine: The convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44-56. <https://doi.org/10.1038/s41591-018-0300-7>
- Wang, X., Peng, Y., Lu, L., Lu, Z., Bagheri, M., & Summers, R. M. (2017). ChestX-Ray8: Hospital-Scale Chest X-Ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 3462-3471. <https://doi.org/10.1109/CVPR.2017.369>

- Xiao, M. (2024). CNN advancements and its applications in image recognition: A comprehensive analysis and future prospects. *Applied and Computational Engineering*, 46, 116-124. <https://doi.org/10.54254/2755-2721/46/20241180>
- Xu, B., & Yang, G. (2025). Interpretability research of deep learning: A literature survey. *Information Fusion*, 115, 102721. <https://doi.org/10.1016/j.inffus.2024.102721>
- Xuan, W., & You, G. (2020). Detection and diagnosis of pancreatic tumor using deep learning-based hierarchical convolutional neural network on the internet of medical things platform. *Future Generation Computer Systems*, 111, 132-142. <https://doi.org/10.1016/j.future.2020.04.037>
- Zhou, W., Liu, X., Bai, H., & He, L. (2024). Intelligent medical diagnosis and treatment for diabetes with deep convolutional fuzzy neural networks. *Information Sciences*, 677, 120802. <https://doi.org/10.1016/j.ins.2024.120802>

ANEXOS

Anexo 1. Entrevista

Preguntas

Entrevista

Objetivo de la entrevista

Recopilar información sobre el proceso actual de diagnóstico de neumonía mediante radiografías de tórax, conocer la perspectiva de los profesionales médicos sobre el uso de herramientas de Inteligencia Artificial (IA) como apoyo diagnóstico, y entender sus expectativas y preocupaciones al respecto.

01

Datos iniciales

Fecha de la entrevista	
Formación Académica	

02

Experiencia y procesos en el diagnóstico

<p>¿Podría describir brevemente su experiencia en la interpretación de radiografías de tórax para el diagnóstico de neumonía? ¿Con qué frecuencia realiza este tipo de diagnóstico?</p>	
<p>Cuando recibe una radiografía de tórax con sospecha de neumonía, ¿Cuál es su proceso habitual para llegar a un diagnóstico?</p>	
<p>¿Existen patrones o hallazgos que suelen ser más difíciles de interpretar o que pueden confundirse con otras patologías? ¿Cuáles?</p>	
<p>¿Considera que hay un margen de error o subjetividad significativo en la interpretación de estas imágenes?</p>	

03 *Percepción sobre Sistemas de IA para Diagnóstico*

<p>¿Está familiarizado/a con el concepto de Inteligencia Artificial (IA) aplicada al diagnóstico médico, específicamente en el análisis de imágenes como las radiografías?</p>	
<p>¿Ha tenido alguna experiencia previa utilizando o interactuando con algún sistema basado en IA para el diagnóstico médico? Si es así, ¿Cuál fue su experiencia?</p>	
<p>¿Cuál es su opinión general sobre el potencial de la IA como herramienta de apoyo para el diagnóstico de enfermedades como la neumonía?</p>	
<p>¿Cuáles serían sus principales preocupaciones o reservas sobre el uso de un sistema de IA para este fin?</p>	

<p>¿Lo vería más útil como una herramienta de cribado inicial, como una segunda opinión para casos dudosos, o de alguna otra forma?</p>	
<p>¿Cómo cree que la implementación de estos sistemas podría impactar la carga de trabajo de los médicos o la calidad de la atención al paciente?</p>	
<p>¿Considera que se necesitaría capacitación específica para que los profesionales médicos utilicen estas herramientas de manera efectiva?</p>	
<p>Si existiera un sistema de IA, validado y con una alta tasa de precisión, capaz de identificar signos de neumonía en radiografías, ¿estaría dispuesto/a a utilizarlo como herramienta de apoyo en su práctica clínica?</p>	

Anexo 2. Componente de Carga y Predicción de Imágenes

```

import React, { useState } from 'react';

function ImageUpload() {
  const [selectedImage, setSelectedImage] = useState(null);
  const [prediction, setPrediction] = useState(null);

  const handleImageChange = (event) => {
    const file = event.target.files[0];
    if (file && file.type.startsWith('image/')) {
      setSelectedImage(URL.createObjectURL(file));
    } else {
      alert("Por favor, selecciona un archivo de imagen válido.");
    }
  };

  const handleSubmit = async () => {
    const fileInput = document.querySelector('input[type="file"]');
    const formData = new FormData();
    formData.append('file', fileInput.files[0]);

    try {
      const response = await fetch('http://localhost:8000/predict', {
        method: 'POST',
        body: formData,
      });
      const data = await response.json();
      setPrediction(data);
    } catch (error) {
      console.error("Error al enviar la imagen:", error);
    }
  };

  return (
    <div>
      <input type="file" accept="image/*" onChange={handleImageChange} />
      {selectedImage && <img src={selectedImage} alt="Vista previa" style={{ maxWidth: '300px' }} />}
      <button onClick={handleSubmit}>Enviar</button>
      {prediction && (
        <div>
          <h3>Diagnóstico: {prediction.diagnosis}</h3>
          <p>Probabilidad: {prediction.probability.toFixed(2)}</p>
        </div>
      )}
    </div>
  );
}

export default ImageUpload;

```