



*Universidad*  
**LATINA** *de Panamá*  
SUMMUM DESIDERIUM SAPIENTIA

FACULTAD DE INGENIERÍA

ESCUELA DE INGENIERÍA BIOMÉDICA E INSTRUMENTACIÓN

“Desarrollo de un modelo de diagnóstico basado en EfficientNet-B0 para la detección de derrame pleural en radiografías de tórax de pacientes adultos”

Proyecto final de graduación presentado como requisito para optar por el título de Licenciatura en Ingeniería Biomédica e Instrumentación en la Universidad Latina de Panamá

Juan Nieto  
C.I.P. 7-713-968

Director:

Ing. Sergio Ibañez

Tutor metodológico:

Mgr. Alfredo Lescher

Panamá, República de Panamá

2025

## **Agradecimientos**

A mis padres, por ser el pilar fundamental de mi vida y brindarme, con esfuerzo, amor y sacrificio, la educación que hoy me permite alcanzar esta meta. Gracias por enseñarme con el ejemplo, por su fe inquebrantable en mí y por acompañarme en cada paso de este camino. Su apoyo ha sido la base sobre la cual he construido mis sueños y mi formación personal y profesional. Este logro es tan mío como de ustedes, pues sin su dedicación y amor incondicional, nada de esto habría sido posible.

Expreso mi más sincero agradecimiento al ingeniero Sergio Ibáñez, mi asesor, por compartir su experiencia, orientación técnica y aportes valiosos que enriquecieron significativamente el desarrollo de esta tesis. Su guía constante, su disposición para resolver dudas y su compromiso con mi trabajo fueron elementos esenciales para lograr un resultado sólido y bien fundamentado.

Asimismo, deseo agradecer al profesor Alfredo Lescher por su constante apoyo, guía y compromiso a lo largo de todo este proceso. Su acompañamiento académico y humano, su disposición para orientar y su confianza en mis capacidades fueron fundamentales para culminar con éxito este proyecto.

Finalmente, a mi amiga Madeline Pérez, por su compañía, motivación incondicional y por estar presente en los momentos más desafiantes de este camino.

## DECLARACIÓN JURADA

Yo JUAN CARLOS NIETO BATISTA con cédula de identidad personal número, 7713-968 estudiante graduando del programa/carrera de LIC. EN INGENIERÍA BIOMÉDICA E INSTRUMENTACIÓN declaro bajo la gravedad del juramento que el material que aparece en este trabajo de graduación, en la opción: TESIS (Tesis, proyecto final, pasantía, otro), es de mi producción intelectual, en razón de lo cual exoneró a la Universidad Latina de Panamá de cualquier responsabilidad relacionado a este aspecto.

Para que conste firmo la presente declaración el día 20 del mes de Agosto del año 2025.

Firma del  
estudiante:



Cédula: 7-713-968

## Índice General

Capítulo 1 .....	12
El Problema .....	12
1.1. Antecedentes del problema de investigación .....	13
1.2. Planteamiento del problema .....	14
1.3. Justificación de la investigación .....	16
1.3.1 Objetivo general .....	18
1.3.2 Objetivo específico .....	18
1.4. Alcance y límites de la investigación .....	18
1.4.1 Alcance .....	18
1.4.2 Límites .....	19
1.5. Línea de investigación .....	20
Capítulo 2 .....	21
2.0 Antecedentes del marco teórico.....	22
2.1 Bases teóricas que sustentan la investigación.....	27
2.2.1 Derrame Pleural .....	27
2.2.2 Tratamientos para el Derrame Pleural .....	28
2.2.3 Método de Diagnóstico del Derrame Pleural .....	29
2.2.4 Inteligencia Artificial .....	30
2.2.5 Machine Learning .....	31
2.2.6 Aprendizaje Profundo .....	31
2.2.7 Redes neuronales convolucionales .....	32
2.2.8 EfficientnetB0 .....	38
2.3 Variables .....	40
2.3.1 Definición conceptual de la variable dependiente .....	40
2.3.2 Definición operacional de la variable .....	40
2.3.3 Definición conceptual de la variable Independiente .....	41
2.3.4 Definición operacional de la variable dependiente .....	42
2.4 Mapa de variable .....	43
2.5 Glosario de Términos .....	44

Capítulo 3 .....	47
Metodología .....	47
3.1 Tipo y diseño de la investigación .....	48
3.2 Población y Muestra .....	49
3.3 Descripción del instrumento de recolección de datos .....	51
3.4 Procedimiento de la investigación .....	51
3.4.1 Planteamiento del problema .....	51
3.4.2 Revisión de la literatura .....	51
3.4.3 Diseño de investigación.....	52
3.4.4 Selección de la muestra .....	52
3.4.8 Diseño de la propuesta.....	53
3.4.9 Informe de resultados .....	60
Capítulo 4 .....	61
Análisis e interpretación de resultados.....	61
4.0 Cumplimiento de objetivos específicos .....	62
4.2 Discusión .....	74
Capítulo 5 .....	76
Conclusiones y recomendaciones .....	77
Bibliografía .....	83
ANEXOS .....	87

### **Índice de Tablas**

Tabla 1 Promedio de la exactitud sin y con aumento de datos para los conjuntos de dato .....	22
Tabla 2 Resultados de AUROC para los experimentos de función de pérdida. Se muestran los resultados de cada patología .....	23
Tabla 3 Tabla de precisión y recuperación .....	24
Tabla 4 Comparación del desempeño con los radiólogos .....	25
Tabla 5 Comparación del desempeño con los radiólogos .....	25

Tabla 6 Exactitud obtenida con el entrenamiento de los 5 entrenamientos .....	26
Tabla 7 Ilustración explicativa de la técnica de transfer-learning .....	37
Tabla 8 Imágenes insertadas al modelo para el entreaamiento .....	62
Tabla 9 Capas del funcionamiento del modelo EfficientNetB0 .....	64
Tabla 10 Reporte de rendimiento por épocas, con fineturning .....	67
Tabla 11 Resultados de AUROC para los experimentos de función de pérdida. Se muestran los resultados de cada patología .....	71
Tabla 12 Reporte de Clasificación del modelo .....	72
Tabla 13 Reporte de Clasificación General .....	73

### Índice de Ecuaciones

Ecuación 1 Perceptron simple .....	33
Ecuación 2 Formula base de Efficientnetb0 .....	36
Ecuación 3 Para calcular F1-Score .....	38
Ecuación 4 Cálculo de precisión .....	38
Ecuación 5 Manera de Calcular Recall .....	39

### Índice de Gráficos

Gráfica 1 Comparación del desempeño con los radiólogos. ....	23
Grafica 2 Evolución del AUC durante el entrenamiento .....	66
Grafica 3 Evolución de la precisión durante el modelo .....	67

Grafica 4 Evolución del Recall Durante el entrenamiento ..... 69

## Índice de Figuras

Figura 1 Ubicación del Derrame Pleural ..... 25

Figura 2 *Relación entre la inteligencia artificial (AI, Artificial Intelligence), el aprendizaje automático* ..... 28

Figura 3 *red neuronal profunda con tres capas ocultas donde se puede visualizar el aprendizaje jerárquico: al avanzar sobre las capas, las características aprendidas son más complejas* ..... 30

Figura 4 *El filtro y la entrada realizan una operación matricial conocida como convolución* ..... 31

Figura 5 Ejemplo de dos operación de pooling distintas (max-pooling y average-pooling) ..... 32

Figura 6 Ilustración de un perceptrón simple. .... 34

Figura 7 Ilustración explicativa de la técnica de transfer-learning. .... 35

Figura 8 Arquitectura de capas del EfficientnetB0 ..... 37

Figura 9 Distribución de edades del dataset ..... 48

Figura 10 Diseño de la propuesta ..... 50

Figura 11 Cantidad de imágenes por clases ..... 51

Figura 12 Procesamiento de imágenes .....	52
Figura 13 Técnicas de aumento de datos usada .....	53
Figura 14 Partes de la construcción del modelo .....	54
Figura 15 Salida del modelo y sus partes .....	55
Figura 16 Imágenes etiquetadas por el modelo .....	61
Figura 17 Matriz de confusión .....	73
Figura 18 Detección automática del modelo .....	75
Figura 19 Ecografía torácica transtorácica: visualización del espacio pleural y patrón artefactual pulmonar .....	86
Figura 20 drenaje pleural con tubo torácico .....	86
Figura 21 Fragmento de código para compilación y ajuste fino del modelo con AdamW y EarlyStopping .....	87
Figura 22 "Fragmento de código en Python para el entrenamiento de un modelo CNN.....	87

## Introducción

En las últimas décadas se ha presenciado un crecimiento notable en el uso de la inteligencia artificial (IA) en el diagnóstico médico por imágenes. Su integración ha mejorado significativamente la precisión, rapidez y eficiencia en la detección de patologías (Davenport & Kalakota, 2019). En particular, las redes neuronales profundas, como las CNN, han demostrado un desempeño comparable o incluso superior al de radiólogos en ciertas tareas diagnósticas (Anderson et al., 2024). La radiografía de tórax es una herramienta fundamental por su bajo costo y amplia disponibilidad, utilizada ampliamente para diagnosticar enfermedades pulmonares y cardiovasculares (Ait Nasser & Akhloufi, 2023). Dentro de las patologías torácicas, el derrame pleural representa un hallazgo clínico relevante asociado a condiciones graves como infecciones, neoplasias o insuficiencia cardíaca (Krishna et al., 2024). Su detección temprana es esencial para reducir complicaciones y guiar adecuadamente el tratamiento.

La interpretación manual de radiografías de tórax es un proceso complejo, influenciado por la experiencia del observador, el cansancio y la carga de trabajo. Se ha documentado una considerable variabilidad interobservador en la detección de hallazgos como el derrame pleural, lo que puede llevar a errores diagnósticos o diagnósticos omitidos (Ait Nasser & Akhloufi, 2023). Esta limitación es especialmente crítica en instituciones con alta demanda o escasez de radiólogos. En este contexto, surge la necesidad de un modelo computacional que actúe como sistema de prediagnóstico automatizado, capaz de distinguir con rapidez y precisión entre radiografías normales y con derrame pleural. Esto permitiría priorizar la atención de pacientes y reducir los tiempos diagnósticos, complementando la labor del especialista con una herramienta confiable y constante (Roller & Malsch, 2024).

El objetivo general de esta investigación es desarrollar un modelo de diagnóstico basado en EfficientNet-B0 para distinguir entre derrame pleural y condiciones.

Esta investigación sigue un enfoque cuantitativo-experimental. Se utilizaron imágenes públicas del repositorio NIH ChestX-ray14, preprocesadas con técnicas de mejora de contraste y normalización. Se empleó la arquitectura EfficientNet-B0, reconocida por su eficiencia computacional y alta precisión diagnóstica (Tan & Le, 2019), adaptada mediante transfer learning. El modelo fue entrenado y validado utilizando particiones estratificadas del dataset, y evaluado con métricas como exactitud, sensibilidad, AUC y matriz de confusión. Se respetaron principios éticos mediante el uso exclusivo de datos anonimizados.

Este trabajo está organizado en cuatro capítulos. El capítulo I expone el problema, la justificación, los objetivos y el contexto de la investigación. El capítulo II desarrolla el marco teórico y los antecedentes relacionados con IA, diagnóstico por imagen y derrame pleural. El capítulo III describe la metodología utilizada, incluyendo el diseño del modelo, los datos empleados y las fases del entrenamiento. El capítulo IV presenta los resultados obtenidos, su análisis e interpretación. Este trabajo cierra con las conclusiones y recomendaciones obtenidas de la investigación.

Esta investigación propone como principal contribución un modelo de prediagnóstico automatizado basado en EfficientNet-B0 para la detección temprana de derrame pleural. Su principal ventaja radica en la capacidad de operar con alta precisión y baja carga computacional, lo que lo hace ideal para entornos con recursos limitados. Además, el estudio aporta evidencia de su posible integración como herramienta de apoyo clínico, mejorando la eficiencia diagnóstica y la toma de decisiones médicas en radiología (AbuKaraki et al., 2024).

# **Capítulo 1**

## **El Problema**

### **1.1. Antecedentes del Problema de Investigación**

El derrame pleural es una condición caracterizada por la acumulación anormal de líquido en la cavidad pleural, el espacio entre las dos capas de la pleura que recubren los pulmones y la cavidad torácica. En función de su origen y composición, puede clasificarse en derrame pleural transudativo y exudativo. El derrame pleural transudativo ocurre por un aumento en la presión hidrostática o una disminución en la presión oncótica, situaciones que se observan en patologías como la insuficiencia cardíaca congestiva, la cirrosis hepática con ascitis o el síndrome nefrótico. Por otro lado, el derrame pleural exudativo se asocia a procesos inflamatorios o infecciosos, como la neumonía bacteriana, la tuberculosis, el cáncer de pulmón y las enfermedades autoinmunes, entre otras (Strumfa et al., 2024; West, 2012). Adicionalmente, se identifica el derrame pleural maligno, caracterizado por la presencia de células tumorales en el líquido pleural, común en pacientes con cáncer de pulmón, mama o linfomas Sahn, S. A. (2021). La presencia de derrame pleural está estrechamente vinculada con una alta tasa de morbilidad y mortalidad, especialmente en pacientes con enfermedades subyacentes. Se ha documentado que la mortalidad a 30 días en pacientes con derrame pleural maligno puede oscilar entre un 30% y 50%, mientras que en infecciones pleurales la tasa alcanza aproximadamente el 20%. Además, la presencia de derrame pleural en pacientes con neumonía complica su evolución, prolongando la estancia hospitalaria y aumentando la necesidad de intervenciones invasivas (Astoul et al., 2022).

El diagnóstico del derrame pleural se basa en un enfoque multimodal que combina técnicas clínicas e imagenológicas. La radiografía de tórax es el método inicial para detectar la acumulación de líquido en la pleura, observándose el velamiento del seno costofrénico y la elevación de la cúpula diafragmática (Gibson, 2021). Sin embargo, en casos de derrames pequeños o de difícil identificación, se recomienda realizar un ultrasonido torácico, ya que proporciona una mayor precisión en la detección de volúmenes reducidos de

líquido. (Tassi & Marchetti, 2020). En situaciones donde se requiere una caracterización más detallada, la tomografía computarizada (TC) es útil para evaluar el engrosamiento pleural y diferenciar entre procesos benignos y malignos (Porcel, 2022). Para establecer un diagnóstico definitivo, se realiza una toracocentesis, procedimiento en el que se extrae líquido pleural para su análisis, diferenciando entre exudados y transudados según los criterios de Light (Light, 2020).

Un diagnóstico tardío o erróneo del derrame pleural tiene un impacto significativo en la calidad de vida del paciente y en la eficiencia del sistema de salud. En pacientes con derrames pleurales malignos, un diagnóstico retrasado puede llevar a una progresión acelerada de la enfermedad, incrementando la disnea, el dolor torácico y la insuficiencia respiratoria, lo cual deteriora la calidad de vida y acorta la supervivencia (Sahn, 2021). Además, el manejo inadecuado de derrames infecciosos puede derivar en efisema pleural, lo que implica la necesidad de procedimientos invasivos, como drenaje pleural o decorticación quirúrgica, aumentando el tiempo de hospitalización y elevando el riesgo de complicaciones (Porcel & Light, 2021). Por lo tanto, la detección temprana y precisa de esta condición es fundamental para optimizar el manejo clínico y mitigar el impacto económico en los sistemas de salud.

## **1.2. Planteamiento del problema**

La radiografía de tórax es una de las herramientas de diagnóstico por imágenes más utilizadas en la práctica médica debido a su accesibilidad, bajo costo y eficacia en la evaluación de diversas patologías pulmonares y torácicas (Gómez et al., 2020). Entre estas patologías, el derrame pleural representa una condición clínica de gran relevancia, caracterizada por la acumulación anormal de líquido en la cavidad pleural (Light, 2013). La detección temprana y precisa de esta afección es crucial para determinar el tratamiento adecuado y mejorar los desenlaces clínicos de los pacientes (Porcel & Light, 2017). Sin embargo, la interpretación de las radiografías de tórax puede estar sujeta a variabilidad entre los radiólogos, lo cual podría generar diagnósticos erróneos o retrasos en la toma de decisiones clínicas (Rahman et al., 2018).

El avance de la inteligencia artificial (IA) ha abierto nuevas posibilidades en el ámbito del diagnóstico por imágenes médicas. En particular, los modelos de redes neuronales convolucionales (CNN) han demostrado un desempeño prometedor en la clasificación de imágenes médicas (LeCun et al., 2015). Entre estos modelos, EfficientNet-B0 se presenta como una opción viable debido a su eficiencia computacional y capacidad para extraer características relevantes de imágenes de alta resolución (Tan & Le, 2019). Su aplicación en el análisis de radiografías de tórax podría mejorar significativamente la precisión en la detección de derrame pleural, proporcionando un apoyo objetivo y consistente a los especialistas médicos (Chen et al., 2021).

La integración de un sistema de prediagnóstico basado en inteligencia artificial permitiría optimizar la toma de decisiones clínicas, reduciendo el margen de error y agilizando el proceso de atención al paciente (Esteva et al., 2019). Este tipo de tecnología facilita la identificación de patrones complejos en imágenes médicas, minimizando la subjetividad inherente a la interpretación humana y mejorando la reproducibilidad de los diagnósticos. Además, la IA puede actuar como un asistente virtual para los radiólogos, proporcionando sugerencias basadas en grandes volúmenes de datos previamente analizados, lo cual facilita la detección de anomalías y permite priorizar de forma efectiva los casos más urgentes.

Este enfoque no busca reemplazar la evaluación médica, sino complementar el análisis radiológico tradicional con una herramienta computacional de apoyo que sugiera la posible presencia de un derrame pleural y oriente la conducta a seguir (Rajpurkar et al., 2017).

Por lo tanto, la presente investigación se centrará en el desarrollo de un modelo de diagnóstico basado en EfficientNet-B0 para distinguir entre pacientes con derrame pleural y aquellos con radiografías normales. Llevando a las siguientes preguntas:

¿Podría este modelo mejorar la precisión en la identificación de casos de derrame pleural en comparación con la evaluación visual realizada por

especialistas? ¿Ayudaría la implementación de este sistema a optimizar el tiempo de diagnóstico y la toma de decisiones médicas? ¿Podría este modelo de IA ser utilizado como una herramienta de segunda opinión en casos ambiguos, reduciendo la variabilidad diagnóstica entre diferentes especialistas?

### **1.3 Justificación de la investigación**

El desarrollo de esta investigación responde a la necesidad de proporcionar al personal médico una herramienta eficiente para la detección del derrame pleural en radiografías de tórax. La incorporación de inteligencia artificial en el diagnóstico médico ha demostrado ser una estrategia prometedora para mejorar la precisión y rapidez en la identificación de patologías, permitiendo una atención más efectiva a los pacientes (Litjens et al., 2017). La detección temprana del derrame pleural mediante algoritmos de deep learning podría optimizar la toma de decisiones clínicas y reducir errores de interpretación (Rajpurkar et al., 2017).

Un estudio de esta naturaleza es fundamental para el desarrollo de la inteligencia artificial en el campo biomédico, puesto que contribuye a la validación y optimización de modelos de aprendizaje profundo. Tecnologías como EfficientNet, previamente empleadas en investigaciones similares, requieren evaluaciones rigurosas para determinar su desempeño en escenarios clínicos reales. EfficientNet se destaca por su capacidad de optimizar el uso de parámetros, logrando un alto rendimiento con menor costo computacional en comparación con otros modelos (Tan & Le, 2019). Además de EfficientNet, otros algoritmos pre-entrenados como VGG16, ResNet y MobileNet han sido ampliamente utilizados en tareas de clasificación de imágenes médicas. Estos modelos, de acceso libre, han demostrado una alta eficacia en la segmentación y clasificación de imágenes biomédicas (Simonyan & Zisserman, 2015; He et al., 2016; Howard et al., 2017).

Asimismo, esta investigación fortalece la línea de inteligencia artificial en la universidad, promoviendo la generación de conocimientos aplicados en el área

de salud. La investigación en modelos de deep learning de acceso libre es crucial, ya que permite a instituciones académicas y hospitales desarrollar soluciones médicas sin depender de software propietario de alto costo. La implementación de estos modelos en problemas médicos permite explorar nuevas fronteras en la investigación biomédica y contribuye al desarrollo de soluciones innovadoras para el sector sanitario, mejorando la accesibilidad a diagnósticos automatizados en regiones con recursos limitados (Esteva et al., 2017).

Para garantizar la efectividad del modelo propuesto, se seguirá un procedimiento estructurado: en primer lugar, se utilizará un dataset de radiografías de tórax con y sin derrame pleural, asegurando la calidad y diversidad de las imágenes seleccionadas. Luego, se procederá a la extracción de las imágenes relevantes y se aplicará la técnica de mejora de contraste CLAHE (Contrast Limited Adaptive Histogram Equalization) con el objetivo de resaltar detalles en las radiografías, y mejorar la visualización de estructuras anatómicas (Zuiderveld, 1994). Posteriormente, se implementará el modelo basado en EfficientNet, aprovechando su arquitectura optimizada para la clasificación de imágenes médicas.

El modelo será entrenado utilizando un conjunto de datos dividido en tres subconjuntos: entrenamiento, validación y prueba, con el fin de garantizar una adecuada generalización mediante técnicas de aumento de datos y regularización. El rendimiento del modelo será evaluado a través de métricas clave como exactitud, sensibilidad y especificidad, proporcionando un análisis detallado de su capacidad de predicción. Finalmente, se analizarán los resultados obtenidos, se compararán con estudios previos y se extraerán conclusiones sobre la eficacia del modelo propuesto en la detección de derrame pleural.

## **1.3 Objetivos**

### **1.3.1 Objetivo general**

Desarrollar un modelo de diagnóstico basado en EfficientNet-B0 para distinguir entre derrame pleural y condiciones normales en radiografías de tórax.

### **1.3.2 Objetivos específicos**

Preprocesar un conjunto de datos de radiografías de tórax utilizando técnicas para mejorar la calidad de las imágenes.

Implementar y ajustar la arquitectura EfficientNet-B0 mediante técnicas de transfer learning para clasificar entre derrame pleural y normal.

Evaluar el rendimiento del modelo mediante métricas de desempeño.

Aplicar el modelo de detección automática de derrame pleural en imágenes individuales de radiografía de tórax.

## **1.4 Alcance y límites de la investigación**

### **Alcance**

El presente estudio tiene como objetivo desarrollar, implementar y evaluar un modelo de diagnóstico basado en EfficientNet-B0 para la detección automática de derrame pleural en radiografías de tórax. Para ello, se llevará a cabo un análisis exhaustivo del estado del arte, explorando modelos previos de inteligencia artificial aplicados al diagnóstico por imágenes médicas.

Posteriormente, se procederá a la fase de preprocesamiento y entrenamiento del modelo, utilizando datasets de imágenes médicas previamente etiquetadas. El modelo será ajustado mediante técnicas de transfer learning, con el fin de mejorar su precisión y optimizar su desempeño en la clasificación de radiografías con y sin derrame pleural.

El desempeño del modelo será evaluado mediante métricas de clasificación estándar, como precisión, sensibilidad, especificidad y área bajo la curva (AUC), comparándolo con estudios previos y métodos convencionales de diagnóstico radiológico. Finalmente, se analizará su potencial aplicabilidad en

entornos clínicos y su viabilidad como herramienta de apoyo en el diagnóstico del derrame pleural.

Este estudio fue realizado dentro de la universidad y comenzó a desarrollarse en noviembre del año pasado, con fecha estimada de finalización en julio de este año.

### Límites

Este estudio presenta diversas limitaciones que deben considerarse al interpretar sus resultados. En primer lugar, el modelo será entrenado y validado utilizando datasets públicos de radiografías de tórax, lo que implica que no se contará con imágenes provenientes de hospitales locales, pudiendo afectar la generalización del modelo a diferentes poblaciones. Asimismo, la investigación se desarrollará en un entorno de prueba y validación computacional, sin implementación en hospitales o evaluación directa por radiólogos en la práctica clínica, lo que limita su aplicación inmediata en entornos médicos reales.

Además, la precisión del modelo dependerá en gran medida de la calidad y diversidad de las imágenes utilizadas para su entrenamiento, lo que podría afectar su rendimiento en estudios radiológicos con condiciones de captura subóptimas o con variaciones anatómicas específicas no contempladas en el dataset. Por otro lado, este estudio se centrará exclusivamente en radiografías de tórax, dejando fuera otras modalidades de imagen como la tomografía computarizada (TC) o la ecografía torácica, que también se utilizan en el diagnóstico del derrame pleural.

Además, este estudio, solo se enfocará en radiografía de tórax de pacientes adultos.

### **1.5 Línea de investigación**

El estudio presentado pertenece a la línea de investigación en ciencias de la salud, específicamente en el tema de Procesamiento de Señales e Imágenes Médicas en el área de Informática Médica, Bioinformática y Telemedicina.

## **Capítulo 2**

### **Marco Teórico**

## 2.1 Antecedentes de investigaciones realizadas en el tema.

En el primer proyecto corresponde a Luciana Simón, proyecto de grado de la Universidad de la Plata González el mismo se titula “**Redes Basadas en Aprendizaje Profundo para la Detección de Anomalías en Radiografías de Tórax**” (2021). El objetivo general del proyecto es estudiar, proponer, implementar y validar redes basadas en aprendizaje profundo para la detección de anomalías en radiografías de tórax. Los objetivos específicos incluyen: realizar un relevamiento de redes neuronales aplicadas a imágenes médicas, estudiar trabajos previos sobre el procesamiento de radiografías de tórax; desarrollar algoritmos y programas para implementar y validar redes neuronales profundas en la detección de anomalías. El proyecto explora el uso de redes neuronales convolucionales (CNN) para la clasificación de imágenes de radiografías de tórax, enfocándose en la identificación de anomalías. Se utilizaron técnicas de transfer-learning con redes pre-entrenadas como VGG19, ResNet50 e InceptionV3 para optimizar el rendimiento del modelo con conjuntos de datos limitados. La base de datos utilizada fue ChestX-ray14, que contiene más de 100,000 imágenes con etiquetas de 14 diferentes patologías. Se aplicaron estrategias de aumento de datos (data augmentation) y validación cruzada para mejorar la generalización del modelo. Los resultados del mismo fueron:

Tabla 1 Promedio de la exactitud sin y con aumento de datos para los conjuntos de dato

Conjunto de datos	Sin aumento de datos	Con aumento de datos
Atelectasia + Sin Hallazgo	68,5%	68,9%
Cardiomegalia + Sin Hallazgo	73,6%	68,9%
Infiltración + Sin Hallazgo	62,0%	62,2%
Masa + Sin Hallazgo	66,6%	67,5%
Nódulo + Sin Hallazgo	64,0%	61,8%
Neumotórax + Sin Hallazgo	75,3%	75,6%

(González, 2021). *Redes basadas en aprendizaje profundo para la detección de anomalías en radiografías de tórax* [Tesis de grado, Universidad Nacional de Mar del Plata]. Repositorio de la Universidad Nacional de Mar del Plata.

En otro tipo de investigación de Ivo Matteo Baltruschat de la Universidad Technische

Universität Hamburg con título “**Deep Learning for Automatic Lung Disease Analysis in Chest X-rays**” (2021).. El propósito de esta investigación es mejorar el análisis automático de enfermedades pulmonares en radiografías de tórax mediante el uso de redes neuronales convolucionales (CNN). Los objetivos específicos incluyen: evaluar sistemáticamente diferentes configuraciones de CNN para la clasificación de enfermedades pulmonares; explorar técnicas avanzadas de preprocesamiento de imágenes, como la supresión de huesos y el recorte automático del campo pulmonar, para mejorar la precisión de los modelos; desarrollar un marco para priorización automática de listas de trabajo en radiología, con el objetivo de reducir los tiempos de entrega de informes en casos críticos. El análisis automatizado de enfermedades pulmonares a través de radiografías de tórax es un desafío debido a la alta resolución espacial de las imágenes, la escasez de conjuntos de datos con anotaciones confiables y la gran variedad de enfermedades. Esta tesis aborda estos problemas mediante el diseño y evaluación de distintas configuraciones de CNN, analizando el impacto de cuatro decisiones clave su arquitectura: funciones de pérdida, inicialización de pesos, estructura

*Tabla 2 Resultados de AUROC para los experimentos de función de pérdida. Se muestran los resultados de cada patología*

Pathology	$L_{BCE}$	$L_{PN-BCE}$	$L_{CW-BCE}$
Cardiomegaly	.903	.900	.889
Emphysema	.879	.868	.813
Edema	.891	.893	.879
Hernia	.895	.882	.856
Pneumothorax	.855	.851	.825
Effusion	.878	.873	.850
Mass	.834	.833	.772
Fibrosis	.801	.791	.760
Atelectasis	.797	.790	.769
Consolidation	.804	.802	.788
Pleural thickening	.785	.784	.749
Nodule	.742	.740	.678
Pneumonia	.745	.742	.722
Infiltration	.704	.701	.690
Average	.822	.818	.788
No findings	.772	.770	.755

Baltruschat, I. M. (2021). *Deep Learning for Automatic Lung Disease Analysis in Chest X-rays* [Tesis doctoral, Technische Universität Hamburg]. Technische Universität Hamburg.

En un tercer estudio, por Jeevarathinam Senthilkumar realizado en la universidad del Paso Texas, titulado “**A Integrated Approach of Deep Learning and Augmented Reality for Pneumonia Detection in Chest X-Ray Images**” (2021), la cual tiene como objetivos: desarrollar un sistema automatizado basado en Deep Learning para la detección de neumonía en imágenes de radiografías de tórax; integrar esta tecnología con Realidad Aumentada (AR) para mejorar la visualización y detección de la enfermedad; implementar una red neuronal convolucional (CNN), específicamente MobileNet, para clasificar imágenes de tórax en dos clases: Normal y Neumonía. Además, propone un enfoque basado en Deep Learning y Realidad Aumentada para mejorar la detección de neumonía en imágenes de radiografías de tórax. Se entrenó un modelo de MobileNet V3 con un conjunto de datos de radiografías de tórax obtenidas de Kaggle, utilizando técnicas de Transfer Learning y optimización con TensorFlow. Luego, se integró este modelo en una aplicación basada en Unity y C#, que permite la visualización de resultados en Microsoft HoloLens Gen 1 mediante un sistema de Bounding Boxes en tiempo real.

Obteniendo los siguientes resultados:

Tabla 3 Tabla de precisión y recuperación

Method	Indicator	T(IoU)			
		0.4	0.5	0.6	0.7
Our Metrics	Precision	0.629	0.499	0.365	0.389
	Recall	0.818	0.816	0.770	0.798

Senthilkumar, J. (2021). *A Integrated Approach of Deep Learning and Augmented Reality for Pneumonia Detection in Chest X-Ray Images* [Tesis de maestría, University of Texas at El Paso]. ScholarWorks@UTEP

En un cuarto estudio investigado, que fue realizado por Pranav Rajpurkar en la Universidad de Stanford, titulado “**Deep Learning for Medical Image Interpretation**” (2021). Con unos objetivos, tales como: desarrollar un modelo de aprendizaje profundo capaz de identificar patologías en radiografías de tórax con una precisión comparable a la de un radiólogo; evaluar la eficacia del modelo en un conjunto de datos clínicos relevantes; comparar el desempeño del modelo con otros enfoques previamente utilizados. La tesis buscaba el uso del aprendizaje profundo para el análisis de imágenes médicas, centrándose en radiografías de tórax. Se presentan varias estrategias de supervisión y representación de datos biomédicos, incluyendo técnicas de aumentación de datos y modelos de procesamiento de lenguaje natural para mejorar la clasificación automática de imágenes médicas. Se obtuvieron los siguientes resultados:

*Tabla 4 Comparación del desempeño con los radiólogos*

Institution	Comparison	Average	Pleural Effusion	Edema	Atelectasis
CheXpert	Radiologists	0.568 (0.542,0.597)	0.671 (0.618,0.727)	0.507 (0.431,0.570)	0.548 (0.496,0.606)
	Models	0.570 (0.543,0.599)	0.621 (0.575,0.670)	0.550 (0.474,0.637)	0.587 (0.529,0.640)
	Models - Radiologists	0.002 (-0.028,0.030)	-0.05 (-0.092,-0.007)	0.043 (-0.033,0.114)	0.039 (-0.029,0.106)
NIH	Radiologists	0.537 (0.515,0.555)	0.642 (0.590,0.690)	0.618 (0.549,0.669)	0.469 (0.423,0.515)
	Models	0.578 (0.551,0.601)	0.673 (0.605,0.734)	0.662 (0.582,0.742)	0.529 (0.454,0.595)
	Models - Radiologists	0.041 (0.010,0.072)	0.032 (-0.019,0.078)	0.044 (-0.028,0.124)	0.060 (-0.003,0.126)

Rajpurkar, P. (2021). *Deep Learning for Medical Image Interpretation* [Tesis doctoral, Stanford University]. Stanford Digital Repository.

Finalizando los antecedentes en un quinto estudio, realizado por Carolina Rosas Alatraste en la Universidad Nacional Autónoma de México (UNAM), con el título “**Herramientas de Inteligencia Artificial Aplicadas al Diagnóstico Temprano de COVID-19 Usando Radiografía de Tórax**”, con los objetivos: desarrollar un modelo basado en Deep Learning para la detección temprana de COVID-19 en radiografías de tórax; implementar y evaluar cinco redes neuronales convolucionales (CNNs) de última generación para la clasificación de imágenes médicas, comparar el rendimiento de las distintas arquitecturas para determinar la más efectiva en la detección de COVID-19. En este estudio se presenta un modelo basado en Deep Learning para la detección de COVID-

19 y otras afecciones pulmonares en radiografías de tórax. Se trabajó con un conjunto de 19,845 imágenes obtenidas de Kaggle, complementadas con 64 radiografías proporcionadas por un hospital en Aguascalientes, México. Se probaron cinco redes neuronales: VGG16, ResNet18, ResNet50, ResNetXt101 e Inception V3.

Obteniendo los siguientes resultados:

*Tabla 5 Exactitud obtenida con el entrenamiento de los 5 entrenamientos*

Red Neuronal usada	Exactitud global	Clase	Exactitud alcanzada por clase
VGG16	0.95	COVID	0.94
		Normal	0.89
		Neumonía Pulmonar	0.99
		Opacidad Pulmonar	0.93
ResNet18	0.97	COVID	0.97
		Normal	0.94
		Neumonía Pulmonar	1
		Opacidad Pulmonar	0.97
ResNet50	0.95	COVID	0.98
		Normal	0.89
		Neumonía Pulmonar	0.98
		Opacidad Pulmonar	0.93
ResNetXt101	0.94	COVID	0.97
		Normal	0.87
		Neumonía Pulmonar	0.97
		Opacidad Pulmonar	0.93
Inception V3	0.98	COVID	0.96
		Normal	0.99
		Neumonía Pulmonar	1
		Opacidad Pulmonar	0.97

Rosas Alatríste, C. (2022). Herramientas de Inteligencia Artificial Aplicadas al Diagnóstico Temprano de COVID-19 Usando Radiografía de Tórax [Tesis de licenciatura, Universidad Nacional Autónoma de México]. UNAM - Dirección General de Bibliotecas

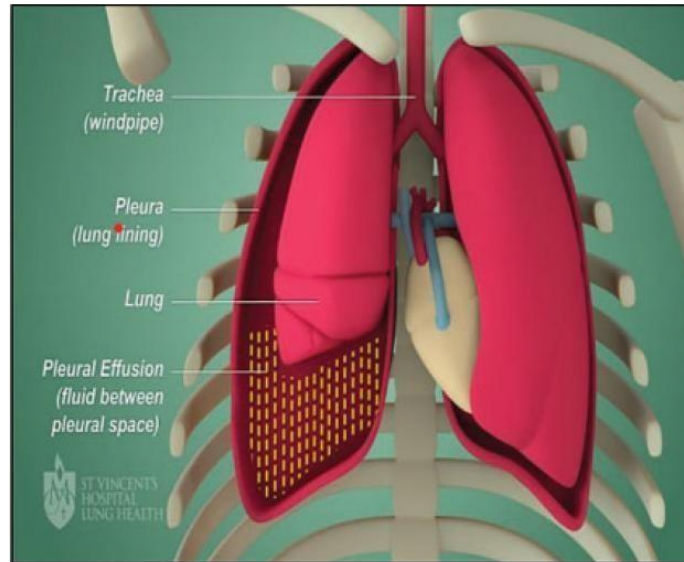
## 2.2 Bases teóricas que sustentan la investigación

### 2.2.1 Derrame pleural

El derrame pleural es la acumulación patológica de líquido en el espacio pleural, la cavidad que separa la pleura visceral (que recubre los pulmones) de la pleura

parietal (que recubre la pared torácica interna), se puede observar mejor en la (figura 1). En condiciones normales, el espacio pleural contiene aproximadamente 10-20 mL de líquido pleural, cuya función es reducir la fricción durante los movimientos respiratorios. Sin embargo, alteraciones en los mecanismos de producción y reabsorción de este líquido pueden generar un derrame pleural (Drake et al., 2020).

*Figura 1 Ubicación del Derrame Pleural*



*Fuente: St Vincent's Hospital Lung Health. (2024)*

El derrame pleural se clasifica en trasudativo y exudativo, dependiendo de sus características bioquímicas y su etiología.

**Derrame pleural trasudativo:** Se debe a un aumento de la presión hidrostática o una disminución de la presión oncótica en los capilares pleurales, lo que provoca la filtración de líquido con bajo contenido proteico. Se observa en enfermedades como insuficiencia cardíaca congestiva, cirrosis hepática y síndrome nefrótico (Kumar et al., 2022).

**Derrame pleural exudativo:** Resulta de procesos inflamatorios o infecciosos que aumentan la permeabilidad capilar, permitiendo la acumulación de líquido con elevado contenido de proteínas y células inflamatorias. Se asocia con patologías como neumonía, tuberculosis, cáncer pleural, embolismo pulmonar e infecciones fúngicas (Guyton and Hall Textbook of Medical Physiology, 2020).

Desde el punto de vista clínico, el derrame pleural puede ser asintomático si es pequeño, pero en casos más avanzados produce disnea progresiva, dolor torácico pleurítico (que se agrava con la respiración profunda), tos seca y, en casos graves, signos de insuficiencia respiratoria. La exploración física puede revelar matidez a la percusión, disminución del murmullo vesicular y egofonía en el área afectada (Drake et al., 2020).

### **2.2.2 Tratamientos para el derrame pleural**

El tratamiento del derrame pleural se centra principalmente en abordar la causa subyacente y aliviar los síntomas asociados con la acumulación de líquido en el espacio pleural. Este tratamiento puede variar desde la simple observación en casos asintomáticos hasta intervenciones médicas y quirúrgicas en casos más graves. La estrategia terapéutica dependerá de factores como la etiología del derrame, el estado general del paciente y la presencia de síntomas. Aquí te detallo tres técnicas comúnmente utilizadas para el tratamiento del derrame pleural, basadas en fuentes académicas actuales.

#### Toracocentesis

Este procedimiento implica la inserción de una aguja en el espacio pleural para drenar el líquido acumulado, proporcionando alivio sintomático y material para análisis diagnóstico. Es un método efectivo para derrames de gran tamaño que causan dificultad respiratoria o cuando se necesita identificar la causa del derrame. Según Light (2020), en su libro *Pleural Diseases*, la toracocentesis no solo alivia la presión y mejora la función pulmonar, sino que también permite un análisis detallado del líquido pleural que puede guiar tratamientos adicionales.

#### Drenaje pleural con tubo torácico

Esta técnica es más invasiva y se utiliza en casos de derrames pleurales complicados, como empiema o derrames de gran volumen. Consiste en la colocación de un tubo de drenaje en el espacio pleural para facilitar la eliminación continua del líquido. Según Marel et al. (2021), en *Journal of*

Thoracic Disease, este método es fundamental para manejar complicaciones y prevenir la recurrencia de derrames, especialmente en contextos de infección o malignidad.

### Pleurodesis

Esta técnica tiene como objetivo eliminar el espacio pleural y prevenir futuras acumulaciones de líquido mediante la introducción de sustancias químicas esclerosantes, como talco, que provocan una reacción inflamatoria y fibrosis. Es especialmente útil en pacientes con derrames malignos recurrentes o crónicos. Según Roberts (2019), en su estudio publicado en Chest, la pleurodesis es efectiva para reducir la tasa de recurrencia en pacientes con derrame pleural maligno.

### **2.2.3 Método de diagnóstico del derrame pleural**

En el proceso de diagnóstico del derrame pleural, es esencial emplear métodos de imagen precisos y detallados que permitan no solo confirmar la presencia del líquido, sino también entender su etiología y guiar el tratamiento adecuado. Las tres técnicas fundamentales de diagnóstico son :

#### Radiografía de tórax

Este es el primer paso en la evaluación de un posible derrame pleural. La radiografía de tórax, en particular en decúbito lateral, es una herramienta efectiva y ampliamente disponible que puede revelar acumulaciones de líquido pleural. Maskell y Butland (2020) destacan su utilidad para detectar derrames y su capacidad para ser realizada rápidamente, ofreciendo una evaluación inicial valiosa que es accesible en la mayoría de los entornos clínicos.

#### Ecografía torácica

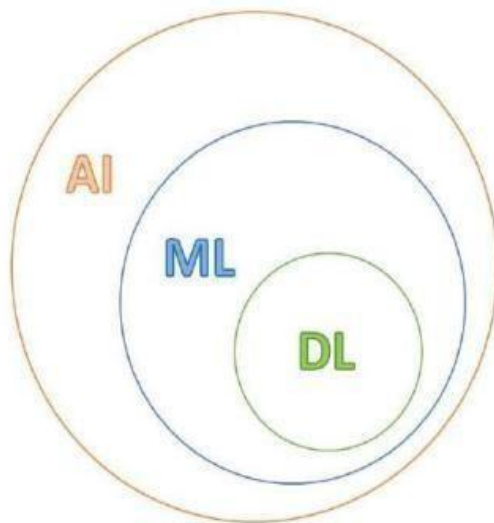
La superioridad de la ecografía sobre la radiografía de tórax radica en su mayor sensibilidad para detectar pequeñas cantidades de líquido pleural. Además, como señalan Corcoran et al. (2022), la ecografía torácica facilita la evaluación en tiempo real de la naturaleza del líquido pleural y es crucial para guiar procedimientos invasivos como la toracocentesis, mejorando así la seguridad y eficacia del diagnóstico.

## Tomografía computarizada (TC) de tórax

Cuando el diagnóstico se complica por factores como la presencia de enfermedades concomitantes o la necesidad de visualización detallada de la anatomía torácica, la TC de tórax se convierte en una herramienta indispensable. Hooper et al. (2021) resaltan su capacidad para proporcionar imágenes detalladas de la estructura del tórax, permitiendo identificar no solo derrames pleurales, sino también otras posibles anomalías que podrían estar contribuyendo al cuadro clínico del paciente.

### **2.2.4 Inteligencia Artificial**

El origen de la inteligencia artificial se remonta a finales de la década de 1940, cuando los pioneros de la computación comenzaron a reflexionar sobre la posibilidad de dotar a las máquinas de capacidades similares al pensamiento humano (Chollet, 2018). Una definición ampliamente aceptada es la propuesta por Andreas Kaplan y Michael Haenlein, quienes describen la IA como "la capacidad de un sistema para interpretar correctamente datos externos, aprender de ellos y utilizar esos conocimientos para lograr tareas y metas específicas a través de la adaptación flexible" (Kaplan & Haenlein, 2019). Desde entonces, y tras más de siete décadas de avances, este campo ha experimentado un crecimiento significativo, incluyendo el desarrollo del aprendizaje automático y el aprendizaje profundo, así como otros enfoques que no necesariamente requieren procesos de aprendizaje.



. Figura 2 Relación entre la inteligencia artificial (AI, Artificial Intelligence), el aprendizaje automático

### **2.2.5 Machine Learning**

El aprendizaje automático (ML) es una rama de la inteligencia artificial que permite a los ordenadores aprender de los datos y mejorar su rendimiento sin necesidad de programación explícita (Russo et al., 2016; Alcobilla Ferrar, 2023). Utiliza herramientas estadísticas y algorítmicas para construir modelos predictivos a partir de grandes conjuntos de datos (Alcobilla Ferrara, 2023; Paixão et al., 2022). El ML tiene aplicaciones en diversos campos, incluida la medicina, donde facilita la interpretación de imágenes y la toma de decisiones clínicas (Alcobilla Ferrara, 2023; Paixão et al., 2022). En el ámbito educativo, se están implementando técnicas de ML e IA para mejorar los procesos de enseñanza-aprendizaje y la gestión educativa en todos los niveles (ForeroCorba y Negre Bennásar, 2023). La construcción de modelos de ML a menudo requiere adaptaciones en función de la naturaleza de los datos o del problema en cuestión (Russo et al., 2016)

### **2.2.6 Aprendizaje Profundo**

El aprendizaje profundo es un subconjunto del aprendizaje automático y la inteligencia artificial que emula el aprendizaje humano para adquirir conocimiento (Angarita, 2020). Ha revolucionado la IA en los últimos años, ampliando los límites de la automatización y el desarrollo de aplicaciones (Vogt,

2019). Las técnicas de aprendizaje profundo procesan datos sin procesar a través de múltiples capas de representación, descubriendo automáticamente características para su detección o clasificación sin intervención humana (LeCun et al., 2015). Este enfoque ha demostrado su eficacia en diversos ámbitos, como el reconocimiento de imágenes, la transcripción del habla y el procesamiento del lenguaje natural.

En la actualidad, el término profundo o deep implica decenas, cientos o incluso miles de capas constituyentes. Cada capa tiene un conjunto de parámetros internos que deben ser ajustados durante el entrenamiento, lo que hace que el número de ejemplos requeridos para tener una buena capacidad de generalización sea alto. Sin embargo, con esta enorme cantidad de neuronas y capas, una DNN puede aprender una gran cantidad de características, siempre que el entrenamiento sea exitoso.

### **2.2.7 Redes neuronales convolucionales**

Dentro de las DNN (Deep Neural Network) o Red Neuronal Profunda Dentro de las, las CNN (Convolutional Neural Network) o Red Neuronal Convolucional son un tipo de red comúnmente utilizada para el reconocimiento y la clasificación de imágenes. Las CNN incluyen una o más capas convolucionales que extraen características de las imágenes de entrada a través de operaciones de convolución. Una imagen digital, en el contexto del PDI, puede ser definida como una función bidimensional o tridimensional discreta. Está compuesta por un número finito de elementos, denominados píxeles, cada uno de los cuales tiene una ubicación y un valor determinados (Gonzales & Woods, 2018). Las CNN son capaces de capturar con éxito las variaciones espaciales en una imagen mediante la aplicación de filtros de convolución, del mismo tipo que los utilizados en PDI para el filtrado espacial. La arquitectura de una CNN típica está conformada principalmente por las siguientes

Capa de convolucional: Esta capa le da nombre a la red y es el elemento central. Las capas convolucionales aplican sistemáticamente filtros espaciales

lineales para crear mapas de características que describen las particularidades de las imágenes de entrada. Cada neurona de una capa convolucional aplica un filtro espacial específico, realizando la convolución matricial. (Goodfellow, Bengio, & Courville, 2016).





Figura 4 El filtro y la entrada realizan una operación matricial conocida como convolución la cual resulta en un mapa de características

Capa de activación: Una vez creado el mapa de características, se pasa cada valor del mapa de características a través de una función de activación que aporta no linealidad, de forma muy parecida a lo que se hace con las salidas de una capa totalmente conectada. La función más comúnmente utilizada es la función ReLU (del inglés Rectified Linear Unit) que, además de permitir mapeos no lineales, es matemáticamente simple y computacionalmente eficiente. (Dubey, Singh, & Chaudhuri, 2021).

Capa de submuestreo o pooling: Una limitación del enfoque convolucional es que las características descubiertas por el filtro dependen fuertemente de la localización espacial de los objetos o texturas presentes. Por lo tanto, la rotación, el desplazamiento u otros cambios menores en la imagen de entrada darán como resultado un mapa de características diferente, cuando es deseable que las características descubiertas sean independientes de estos cambios. Para abordar este problema se utiliza la capa de pooling, en la cual los valores resultantes del filtrado son submuestreados, reduciendo el tamaño final de las matrices. En la Figura 5 se muestran dos ejemplos de pooling con un tamaño 2x2. En max-pooling la matriz resultante se obtiene como el máximo

de los valores contenidos en regiones de 2 por 2 píxeles. En el caso del averagepooling se reemplazan por el promedio. La idea del pooling es cubrir una región mayor del espacio, ampliando el campo de “aprendizaje” de la red haciéndolo más general. (Gholamalinezhad & Khosravi, 2020)

Figura 5 Ejemplo de dos operaciones de pooling distintas (max-pooling y average-pooling)



Capa totalmente conectada o fully connected: Típicamente se alternan capas de conexión, ya que es una forma de aprender combinaciones no lineales de las características de alto nivel representadas por la salida de la capa convolucional.

Además de las capas anteriores, las CNN pueden incluir capas con perceptrones, con La estructura general de las CNN puede dividirse en dos fases (ver Figura 6): la fase de extracción de características y la fase de clasificación.

La estructura general de las CNN puede dividirse en dos fases : la fase de extracción de características y la fase de clasificación.

La fase de extracción. Se caracteriza porque alterna varias capas de neuronas convolucionales, capas de activación y capas de submuestreo (pooling) que reducen subsecuentemente la cantidad de información (píxeles). Como resultado, la salida de esta fase puede interpretarse como un conjunto de

características asociadas a la imagen ingresada. El apilamiento de capas convolucionales en esta fase es lo que permite realizar una descomposición jerárquica de la entrada y que las capas más profundas del modelo aprendan características más abstractas (complejas).

Para entender la última fase que la constituye un perceptrón debemos definir primeramente el mismo. El perceptrón (modelo matemático de una neurona artificial) es la unidad básica de una red neuronal, que toma varias entradas, les asigna pesos, las suma y pasa el resultado por una función de activación para generar una salida. Por lo general, se hace uso de un umbral  $\Theta$  para desplazar.

El límite de decisión entre una clase u otra. La salida del perceptrón se obtiene a partir de la especialización de la función de activación en el valor que resulta de la suma de cada una de las entradas  $x_1, x_2, \dots, x_n$  pesadas por los pesos  $w_1, w_2, \dots, w_n$ , menos el umbral  $\Theta$ , es decir, formalmente, la salida  $Y$  se obtiene como:

*Ecuación 1 Perceptron simple*

$$Y = \phi(v_i) = \phi\left(\sum_{i=1}^n x_i w_i - \phi\right)$$

Para entender mejor un perceptrón se puede ver la siguiente Imagen:




Figura 6 Ilustración de un perceptrón simple. La salida  $Y$  corresponde a la función de activación  $\phi$  especializada en el valor resultante de la suma pesada de cada entrada menos el factor de umbral  $\Theta$ .

La fase de clasificación es una red neuronal tradicional: del tipo perceptrón multicapa, cuya arquitectura se ajusta según la clasificación a realizar. La cantidad de neuronas de salida iguala la cantidad de clases.


Un último paso, opcional, es el fine-tuning, que consiste en descongelar todo el modelo ya entrenado (o parte de él), y volver a entrenarlo con los nuevos datos con una tasa de aprendizaje muy baja. De este modo se pueden conseguir mejoras significativas, adaptando de forma incremental las características preentrenadas a los nuevos datos. Aunque, en general, sólo se toman del modelo pre-entrenado las capas de la fase de clasificación, existen diferentes enfoques de transfer-learning en la bibliografía, algunos de los cuales sólo reemplazan y reentrenan la última capa de la fase de clasificación. En este sentido, se entiende como transfer-learning todo enfoque en el que se reutilicen capas de una red entrenada previamente. El mismo se utiliza en este proyecto (Howard & Ruder, 2018).

Las principales arquitecturas de CNN surgieron del ImageNet Large-Scale Visual Recognition Challenge (ILSVRC) (Deng et al., 2009), un concurso de visión computacional desarrollado anualmente desde 2010 y hasta 2017, a partir de subconjuntos de datos obtenidos de ImageNet. Algunas de las arquitecturas preentrenadas que surgieron en el marco de este concurso son: AlexNet (Krizhevsky, Sutskever, & Hinton, 2012), VGGNet (Simonyan & Zisserman, 2015), Inception (GoogLeNet) (Szegedy et al., 2015), ResNet (He, Zhang, Ren, & Sun, 2016), DenseNet (Huang, Liu, Van Der Maaten, & Weinberger, 2017), EfficientNetB0 (Tan & Le, 2019) entre otras.

Un enfoque ampliamente utilizado en la implementación práctica de las CNN para resolver el problema de la escasez de datos etiquetados (muy habitual al trabajar con imágenes médicas) es el transfer-learning (Bhattacharya et al., 2021). Éste consiste en utilizar una CNN previamente entrenada y reemplazar la fase de clasificación por un nuevo clasificador para reentrenar la red con el conjunto de imágenes de interés, reajustando sólo los parámetros internos de la fase de clasificación; lo que reduce drásticamente el tiempo de

entrenamiento y el número de ejemplos necesarios. En la Figura 8 se muestra un esquema general del enfoque de transfer-learning.

Tabla 7 Ilustración explicativa de la técnica de transfer-learning



### 2.2.8 EfficientnetB0

EfficientNet-B0 es una arquitectura de red neuronal convolucional (CNN) propuesta por Mingxing Tan y Quoc V. Le en 2019. Su principal innovación es un método de escalado compuesto que equilibra simultáneamente la profundidad, la amplitud (ancho de capas) y la resolución de entrada de la red, mejorando la precisión y reduciendo el costo computacional (Tan & Le, 2019). A diferencia de los enfoques tradicionales que escalan estas dimensiones por separado, EfficientNet-B0 utiliza un coeficiente compuesto  $\phi$  para ajustarlas de forma uniforme. En términos matemáticos, la fórmula básica de este escalado es:

*Ecuación 2 Formula base de Efficientnetb0*

$$d = a^\phi, w = \beta^\phi, r = \gamma^\phi$$


$$a. \beta^2. \gamma^2 \approx 2$$

Donde  $d$ ,  $w$  y  $r$  representan la profundidad de capas, el ancho (número de canales) y la resolución de la imagen, respectivamente, mientras que  $\alpha$ ,  $\beta$  y  $\gamma$  son constantes determinadas mediante búsqueda en un espacio de modelos reducido. Por ejemplo, en EfficientNet-B0 se halló que  $\alpha \approx 1.2$ ,  $\beta \approx 1.1$  y  $\gamma \approx 1.15$  bajo dicha restricción (Tan & Le, 2019). Este enfoque de escalamiento compuesto permite obtener una familia de modelos EfficientNet B0–B7 más precisos sin necesidad de ajustar manualmente cada parámetro de escalado.

En cuanto a su estructura de capas, EfficientNet-B0 se compone de una capa inicial de convolución  $3 \times 3$  (32 filtros) y una serie de bloques MBConv organizados en niveles de resolución decreciente (Howard et al., 2019). Estos bloques MBConv (con factor de expansión 1 o 6) utilizan convoluciones *depthwise* y conexiones residuales para mantener la eficiencia, y cada uno integra un módulo *Squeeze-and-Excitation* que responderá dinámicamente los canales más relevantes (Hu et al., 2018). El modelo opera típicamente con imágenes de entrada RGB de  $224 \times 224$  píxeles (Deng et al., 2009). A medida que la imagen avanza por la red, la resolución espacial se reduce (por ejemplo, a  $112 \times 112$ ,  $56 \times 56$ , etc.), mientras se aumenta el número de canales en etapas sucesivas (Tan & Le, 2019). Finalmente, EfficientNet-B0 expande la representación a 1280 canales con una convolución  $1 \times 1$ , aplica *pooling* global y una capa completamente conectada para producir la clasificación final.

Cabe destacar que EfficientNet-B0 fue obtenido mediante búsqueda automatizada de arquitectura (NAS), optimizando la precisión versus el número de operaciones de cómputo (FLOPs) (Tan & Le, 2019). Gracias a este diseño equilibrado, EfficientNet-B0 logra alrededor de 77.1% de precisión top-1 en ImageNet con solo 5.3 millones de parámetros, superando a modelos previos mucho más grandes como ResNet-50 (76.0% con 26 millones de parámetros) en eficiencia (Tan & Le, 2019).

Figura 8 Arquitectura de capas del EfficientnetB0



## 2.3 Variables

### 2.3.1 Definición conceptual de la variable dependiente

El rendimiento del modelo se define como el conjunto de resultados cuantificables que reflejan la capacidad del sistema de inteligencia artificial en este caso, un modelo de red neuronal convolucional basado en EfficientNet-B0 para aprender, generalizar y clasificar adecuadamente imágenes de radiografías de tórax durante un proceso de entrenamiento supervisado. Este rendimiento se expresa mediante métricas cuantitativas como el F1-score, recall (sensibilidad), precisión, especificidad, accuracy y AUC calculadas sobre los conjuntos de validación y prueba.

### 2.3.2 Definición operacional de la variable

El rendimiento del modelo se evalúa mediante el valor cuantitativo de métricas específicas que reflejan su capacidad para clasificar correctamente las imágenes con y sin derrame pleural. Estas métricas son calculadas automáticamente al finalizar el entrenamiento y validación del modelo sobre un conjunto de prueba independiente.

En este estudio, el rendimiento se operacionaliza a través de las siguientes métricas:

- F1-score: Indicador principal del rendimiento global, que combina precisión y sensibilidad en una sola métrica balanceada.

Ecuación 3 Para calcular F1-Score

$$F1 = 2 \left( \frac{Precision \cdot Recall}{Precision + Recall} \right)$$

- Precisión: Mide la proporción de verdaderos positivos entre los casos que el modelo clasificó como positivos.

Ecuación 4 Calculo de precisión

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

- Recall: Mide la proporción de verdaderos positivos correctamente identificados entre todos los casos positivos reales.

Ecuación 5 Manera de Calcular Recall

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

TP (True Positives): Casos en los que el modelo predijo correctamente la clase positiva (derrame pleural).

TN (True Negatives): Casos en los que el modelo predijo correctamente la clase negativa (sin derrame pleural).

FP (False Positives): Casos negativos que fueron clasificados incorrectamente como positivos por el modelo.

FN (False Negatives): Casos positivos que fueron clasificados incorrectamente como negativos por el modelo.

AUC-ROC: Representa la capacidad del modelo para distinguir entre clases en diferentes umbrales de decisión.

### **2.3.3 Definición conceptual de la variable independiente**

La EfficientNet-B0 es una arquitectura de red neuronal convolucional profunda optimizada para tareas de clasificación de imágenes. Se caracteriza por su eficiencia en el uso de parámetros y recursos computacionales, gracias a una técnica de escalado compuesto que equilibra de forma conjunta la profundidad, la resolución y el ancho de la red. En este estudio, EfficientNet-B0 actúa como la arquitectura base del modelo de aprendizaje supervisado utilizado para la detección automática de derrame pleural en radiografías de tórax. Esta red fue seleccionada por su capacidad comprobada para lograr altos niveles de precisión con menos parámetros en comparación con otras redes más grandes, lo que la hace ideal para aplicaciones médicas con restricciones de procesamiento. Tan, M., & Le, Q. V.

(2019).

### **2.3.4 Definición operacional de la variable dependiente**

La variable EfficientNet-B0, en su dimensión operacional, corresponde a la arquitectura de red neuronal convolucional implementada como modelo de clasificación binaria en la detección de derrame pleural en radiografías de tórax. Su operacionalización se realiza a través de dos dimensiones principales. La primera es el número de imágenes procesadas del dataset, que representa la cantidad de radiografías que han sido preprocesadas y utilizadas como entrada

en el entrenamiento del modelo, lo cual influye directamente en la calidad del aprendizaje supervisado. La segunda dimensión es la optimización del modelo, que se mide mediante el número de épocas de entrenamiento, es decir, la cantidad de iteraciones completas en las que el modelo ajusta sus parámetros utilizando técnicas de transfer learning y fine-tuning sobre los pesos preentrenados.

## 2.4 Mapa de variable

<p><b>OBJETIVO GENERAL</b></p>	<p>Desarrollo de un modelo de diagnóstico basado en EfficientNet-B0 para la detección de derrame pleural en radiografías de tórax de pacientes adultos.</p>		
<p><b>OBJETIVOS ESPECIFICOS</b></p>	<p><b>VARIABLES</b></p>	<p><b>DIMENSIONES</b></p>	<p><b>INDICADORES</b></p>
<p>1. Preprocesar un conjunto de datos de radiografías de tórax utilizando técnicas para mejorar la calidad de las imágenes.</p>	<p>EfficientnetB0</p>	<p>Imágenes a procesar del dataset</p>	<p>Numero de imágenes procesadas para el entrenamiento</p>

<p>2. Implementar y ajustar la arquitectura EfficientNetB0 mediante técnicas de transfer learning para clasificar entre derrame pleural y normal.</p>		<p>Optimización del modelo (ajustes en capas y pesos preentrenados)</p>	<p>Numero de épocas en el entrenamiento</p>
<p>3. Evaluar el rendimiento del modelo mediante métricas de desempeño.</p>		<p>Análisis de matriz de confusión Curva AUC Número de TP, TN, FP y FN</p>	<p>Precisión Sensibilidad Acurracy Área bajo la curva (AUC) F1-Score Recall</p>
<p>4. Aplicar el modelo de detección automática de derrame pleural en imágenes individuales de radiografía de tórax.</p>	<p>Rendimiento</p>	<p>Detección automática de casos con derrame y normales</p>	<p>Exactitud de imágenes con derrame Exactitud de imágenes normales.</p>

## 2.5 Glosario de términos

- **Derrame pleural:** Acumulación anormal de líquido en el espacio pleural (entre las membranas que recubren los pulmones y la pared torácica), lo cual puede comprometer la expansión pulmonar normal. (Jiménez & Camacho, 2009).
- **Toracocentesis:** Procedimiento médico invasivo que consiste en puncionar con una aguja el espacio pleural para aspirar y extraer el

líquido acumulado (derrame pleural), ya sea con fines diagnósticos o terapéuticos. (Dezube, 2022).

- **Drenaje pleural con tubo torácico:** Colocación de un tubo de tórax (catéter flexible) a través de la pared torácica hasta el espacio pleural, con el objetivo de drenar el aire, líquido (ej. derrame pleural) o pus allí acumulados y así aliviar la compresión del pulmón. (Clínica Universidad de Navarra, n.d.).
- **Pleurodesis:** Procedimiento destinado a obliterar (cerrar) de forma permanente el espacio pleural mediante la adherencia de la pleura visceral a la parietal. (Clínica Universidad de Navarra, n.d.).
- **Radiografía de tórax:** Estudio de imagen diagnóstica obtenido con rayos X del pecho, que produce imágenes de las estructuras intratorácicas como el corazón, pulmones, vías respiratorias, vasos sanguíneos y huesos de la cavidad torácica. (RadiologyInfo, n.d.)
- **Ecografía torácica:** Técnica de imagen que emplea ultrasonido para examinar en tiempo real las estructuras del tórax –incluyendo pleura, pulmones, pared torácica y diafragma– y detectar anomalías. (Rahman, 2023).
- **Tomografía computarizada (TC) de tórax:** Estudio de imagen que utiliza rayos X con procesamiento computarizado para generar cortes transversales detallados del tórax (Dezube, 2022).
- **Inteligencia artificial:** Área de la informática que se enfoca en desarrollar sistemas o programas capaces de realizar tareas que normalmente requieren inteligencia humana (por ejemplo, aprender, razonar, tomar decisiones o resolver problemas).
- **Machine learning (aprendizaje automático):** Subcampo de la inteligencia artificial que diseña y aplica algoritmos para que las computadoras “aprendan” a partir de datos y mejoren su desempeño en tareas específicas sin instrucciones explícitas para cada posible situación. (Russell & Norvig, 2010).

- **Aprendizaje profundo:** Conjunto de técnicas avanzadas de *machine learning* basadas en redes neuronales artificiales de múltiples capas (redes profundas). (Microsoft, 2024).
- **Redes neuronales convolucionales (CNN):** Tipo de red neuronal artificial especializada en el procesamiento de datos con estructura espacial, como las imágenes.
- **Transfer learning (aprendizaje por transferencia):** Técnica de aprendizaje automático en la que el conocimiento adquirido por un modelo al entrenarse en una tarea o dominio de origen se transfiere y reutiliza en una tarea diferente pero relacionada.
- **EfficientNetB0:** Arquitectura base de la familia de redes neuronales convolucionales EfficientNet, propuesta por Tan y Le (2019) para optimizar la eficiencia en visión por computadora. EfficientNetB0 introdujo un método de *escalamiento compuesto* que ajusta de forma balanceada la profundidad, la anchura y la resolución de la red. (Tan & Le, 2019).

# **Capítulo 3**

## **Marco Metodológico**

### **3.1 Tipo y diseño de la investigación**

Una investigación cuantitativa es aquella que recolecta y analiza datos numéricos de manera sistemática con el objetivo de responder preguntas de investigación específicas y probar hipótesis mediante procedimientos estadísticos rigurosos (Creswell, 2014). Este tipo de investigación se apoya en instrumentos estructurados y en el uso de estadísticas para la interpretación de los hallazgos, se busca cuantificar el fenómeno de interés y validar hipótesis a través de datos numéricos (Hernández-Sampieri & Mendoza, 2018).

En el caso de esta tesis, el enfoque es claramente cuantitativo. El desarrollo de un modelo de diagnóstico asistido por computadora basado en EfficientNet-B0 implicó el manejo de un gran volumen de datos numéricos: pixelaciones de imágenes radiográficas y etiquetas binarias (presencia/ausencia de derrame pleural). La eficacia del modelo se evaluó con métricas cuantitativas como exactitud, sensibilidad y especificidad, entre otras.

Por otra parte, la investigación aplicada se orienta a la resolución de problemas concretos mediante la aplicación de conocimientos y técnicas científicas existentes (OCDE, 2015). Según la OCDE (2015), se define como “trabajos originales realizados para adquirir nuevos conocimientos, pero dirigidos fundamentalmente hacia un objetivo práctico específico” (p. 378).

Esta tesis corresponde a una investigación aplicada, ya que su propósito es desarrollar una herramienta tecnológica que mejore un proceso en la práctica médica: un modelo de IA capaz de detectar derrames pleurales en radiografías de tórax. El estudio utiliza conocimientos existentes de aprendizaje profundo y los integra para resolver un problema del mundo real (Salusplay, 2021).

El diseño de la investigación es el plan que será ejecutado partiendo del planteamiento del problema para llegar a una solución. Puede ser experimental o no experimental dependiendo de cómo se recolectan los datos.

Según Hernández-Sampieri y Mendoza (2018), los estudios con diseño no experimentales no se manipulan deliberadamente variables dependientes, sino que se observan los fenómenos en su ambiente natural para analizarlos. Manterola et al. (2019) señalan que los estudios observacionales se caracterizan por la observación y el registro de acontecimientos sin intervenir en su curso natural.

El presente trabajo tiene un diseño no experimental, ya que no hubo manipulación de la variable dependiente llamada recall . Se utilizó un conjunto de datos existente (ChestX-ray14) y se entrenó un modelo de aprendizaje automático. El análisis se realizó ex post facto, evaluando relaciones entre variables ya presentes en la base de datos.

Así mismo, un estudio transversal recolecta datos en un solo momento o periodo único, sin seguimiento posterior (Manterola et al., 2019). A diferencia del enfoque longitudinal, no se observa la evolución de las variables a lo largo del tiempo.

Este trabajo es transversal porque todas las mediciones se realizaron en un solo momento, utilizando un conjunto fijo de datos históricos. No hubo seguimiento de pacientes ni múltiples observaciones temporales, por lo tanto, se tomó una "fotografía" de los datos disponibles para entrenar y evaluar el modelo (Nguyen et al., 2020).


### **3.2 Población y muestra**

En este estudio se utilizó el conjunto de datos XHChest14 del NIH (National Institutes of Health), enfocado en imágenes radiográficas de tórax. La muestra seleccionada consistió en 5500 imágenes, de las cuales el 85% fue destinado al entrenamiento del modelo, mientras que el 15% restante se distribuyó entre validación y prueba para evaluar el desempeño del algoritmo. La distribución por rangos de edad de los pacientes incluidos se muestra en las gráficas obtenidas, donde se observa que el grupo más representado fue el de 40-60 años con un 46.3%, seguido del grupo de 60-80 años con un 31.4%, y

finalmente el grupo de 2040 años con un 22.2%. Esta distribución etaria es relevante para comprender el sesgo potencial del modelo al entrenarse con una mayor proporción de casos en edades medias a avanzadas. Se recolectaron exclusivamente las imágenes correspondientes al diagnóstico de derrame pleural, obteniendo un total aproximado de 7,000 radiografías de tórax. Estas imágenes provinieron de 1,600 pacientes y fueron extraídas del repositorio público NIH ChestX-ray14. Se excluyeron alrededor de 10,000 imágenes adicionales que presentaban derrame pleural combinado con otros diagnósticos, como atelectasia, neumonía y otras patologías torácicas, con el fin de garantizar la pureza de las clases y mejorar la precisión del modelo de clasificación.

El conjunto de datos ChestX-ray14 fue desarrollado por el National Institutes of Health (NIH) y etiquetado automáticamente mediante técnicas de procesamiento de lenguaje natural (NLP), sin intervención directa de radiólogos en la mayoría de las imágenes. Las etiquetas fueron extraídas a partir de los informes radiológicos asociados a cada imagen utilizando las herramientas DNorm y MetaMap, y se aplicaron reglas sintácticas para eliminar menciones negadas o inciertas. Se eligió este dataset por su escala hospitalaria realista, su disponibilidad pública y su idoneidad para el entrenamiento de algoritmos de aprendizaje profundo. Además, al seleccionar imágenes que solo presentan derrame pleural como diagnóstico único, se garantiza un entrenamiento más limpio y específico, reduciendo el ruido causado por diagnósticos múltiple

Figura 9 Distribución de edades del dataset



### **3.3 Descripción del instrumento de recolección de datos**

El instrumento de recolección de datos utilizado en este estudio fue el conjunto de datos XHChest14, proporcionado por el National Institutes of Health (NIH). Este dataset está compuesto por radiografías de tórax en formato digital (DICOM) obtenidas a partir de estudios clínicos realizados en el NIH Clinical Center, e incluye metadatos asociados como edad, sexo y diagnóstico patológico etiquetado mediante técnicas de procesamiento de lenguaje natural aplicadas a informes médicos.

### **3.4 Procedimiento de la investigación**

#### **3.4.1 Planteamiento del problema**

La radiografía de tórax es una herramienta clave en el diagnóstico de patologías pulmonares como el derrame pleural, una acumulación anormal de líquido en la cavidad pleural que requiere detección temprana para un tratamiento oportuno. Sin embargo, su interpretación puede variar entre especialistas, generando diagnósticos erróneos o retrasados. Ante esta limitación, la inteligencia artificial, y en particular las redes neuronales convolucionales como EfficientNet-B0, ofrecen una solución prometedora al automatizar la clasificación de imágenes con alta precisión. Este modelo destaca por su eficiencia computacional y capacidad para identificar patrones complejos en radiografías, mejorando la detección del derrame pleural. Su integración como sistema de apoyo diagnóstico no busca sustituir al médico, sino complementar su análisis con una herramienta objetiva, rápida y reproducible, que optimiza la toma de decisiones clínicas y prioriza los casos más urgentes.

#### **3.4.2 Revisión de la literatura**

Para la realización de esta investigación, se utilizaron múltiples documentos que aportaron información valiosa en cada uno de los capítulos. En el Capítulo 1, se emplearon 26 documentos de apoyo, entre los cuales se incluyen libros especializados, artículos científicos, y fuentes web confiables, que permitieron sustentar teóricamente la importancia de la radiografía de tórax y el uso de inteligencia artificial en el diagnóstico del derrame pleural.

En el Capítulo 2, durante el desarrollo de los antecedentes, se utilizaron 5 tesis académicas internacionales que proporcionaron experiencias previas en el uso de redes neuronales profundas para el análisis de imágenes médicas. Por su parte, en las bases teóricas se incluyeron 35 documentos adicionales, entre ellos libros de texto, artículos científicos, guías especializadas y normativas técnicas, que permitieron fundamentar de forma sólida los conceptos de aprendizaje profundo, arquitectura EfficientNet y técnicas de procesamiento de imágenes aplicadas al diagnóstico médico.

El capítulo 3 consta de 3 libros, que se utilizaron para definir y justificar el tipo y diseño de la investigación.

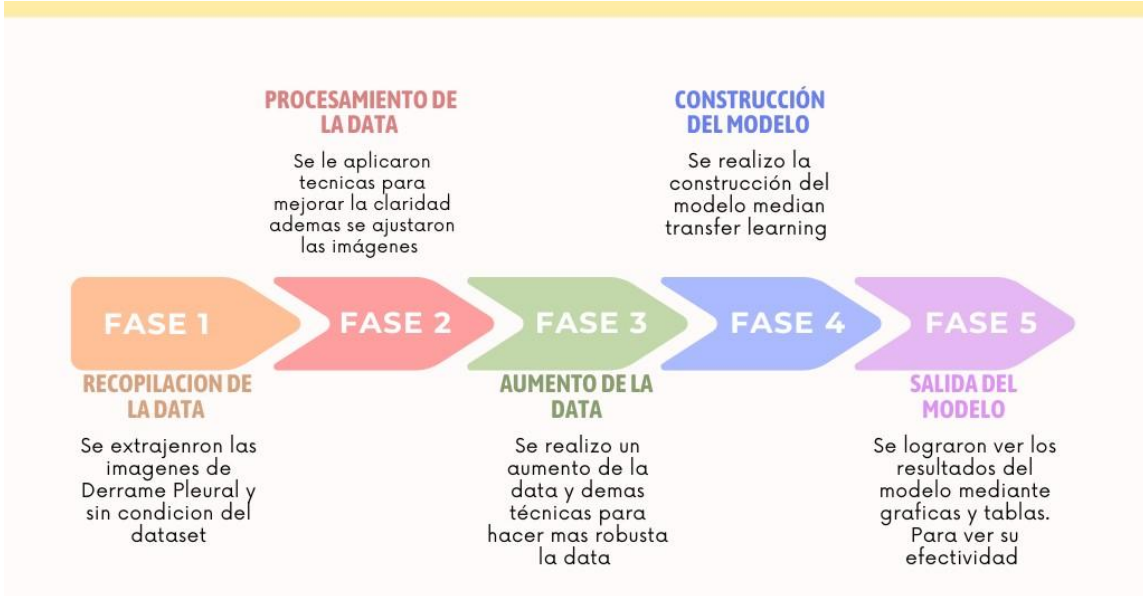
### **3.4.3 Diseño de investigación**

Esta investigación es de tipo aplicada, ya que busca resolver un problema específico en el ámbito médico mediante la implementación de un modelo de inteligencia artificial basado en EfficientNet. El propósito principal es mejorar el diagnóstico de derrame pleural a partir del análisis automatizado de radiografías de tórax, contribuyendo así a la optimización de los procesos clínicos.

### **3.4.4 Selección de la muestra**

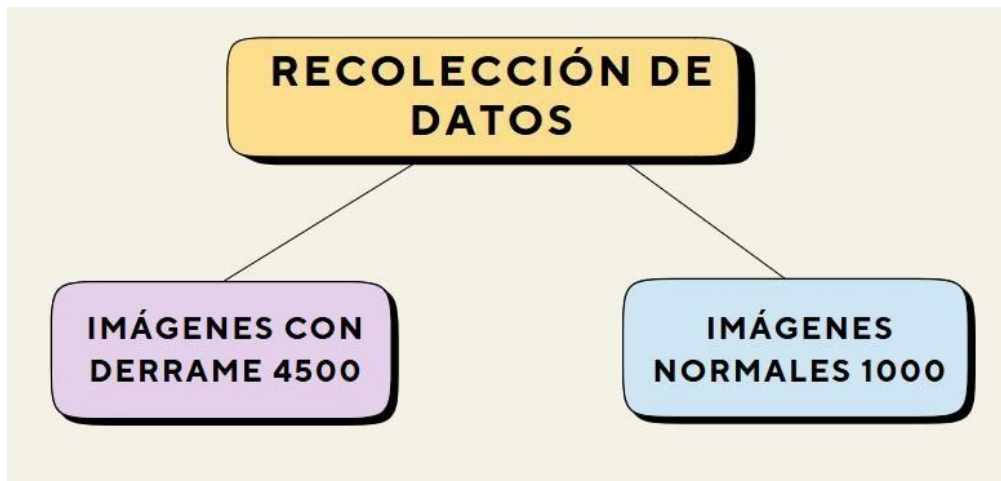
En esta investigación se aplicó un muestreo no probabilístico de tipo intencional, ya que la selección de los datos se basó en criterios específicos vinculados a los objetivos del estudio se recolectaron todas las imágenes. La muestra estuvo conformada por aproximadamente 7,000 imágenes de radiografías de tórax, correspondientes a 1,600 pacientes, las cuales fueron extraídas del repositorio público NIH ChestX-ray14.

### 3.4.8 Diseño de la propuesta



#### 1. Recopilación de la data

Ilustración 12 Distribución de imágenes



Se reunieron 5500 imágenes radiografías de tórax provenientes del dataset NIH Xchest. De ellas, 4500 presentan derrame pleural y 1000 son radiografías sin dicha condición. Este marcado desbalanceo de clases (aproximadamente 80% casos positivos vs. 20% negativos) puede deberse a la prevalencia real

del derrame pleural en la población estudiada o a un sesgo intencional al recolectar datos clínicos enfocados en dicha patología (Rajpurkar et al., 2017).

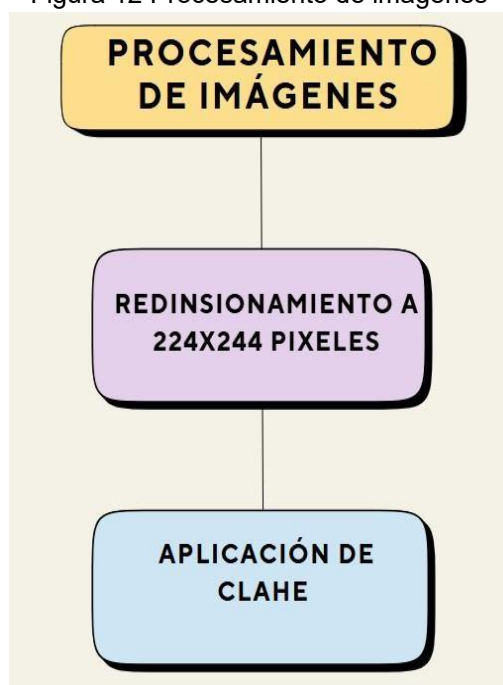
El desbalanceo de clases tiene implicaciones importantes: numerosos estudios han demostrado que desequilibrios severos pueden degradar el rendimiento de los modelos de clasificación, ya que el modelo tiende a sesgarse hacia la clase mayoritaria (Buda et al., 2018). En nuestro caso, un modelo entrenado directamente con 5000 radiografías con derrame y 2000 sin él podría aprender a predecir siempre

“derrame pleural” dado que esta clase domina, obteniendo alta exactitud aparente, pero fallando en detectar correctamente los casos negativos.

Para enfrentar este problema, se consideraron estrategias para datos desbalanceados. Una técnica común es aplicar ponderación de clases (class weighting) durante el entrenamiento: esto asigna mayor peso a los errores en la clase minoritaria, obligando al modelo a prestar más atención a esta (Chollet, 2017). Otras estrategias incluyen sobre-muestreo o sub-muestreo de clases (Buda et al., 2018)

## 2. Procesamiento de Imágenes

Figura 12 Procesamiento de imágenes

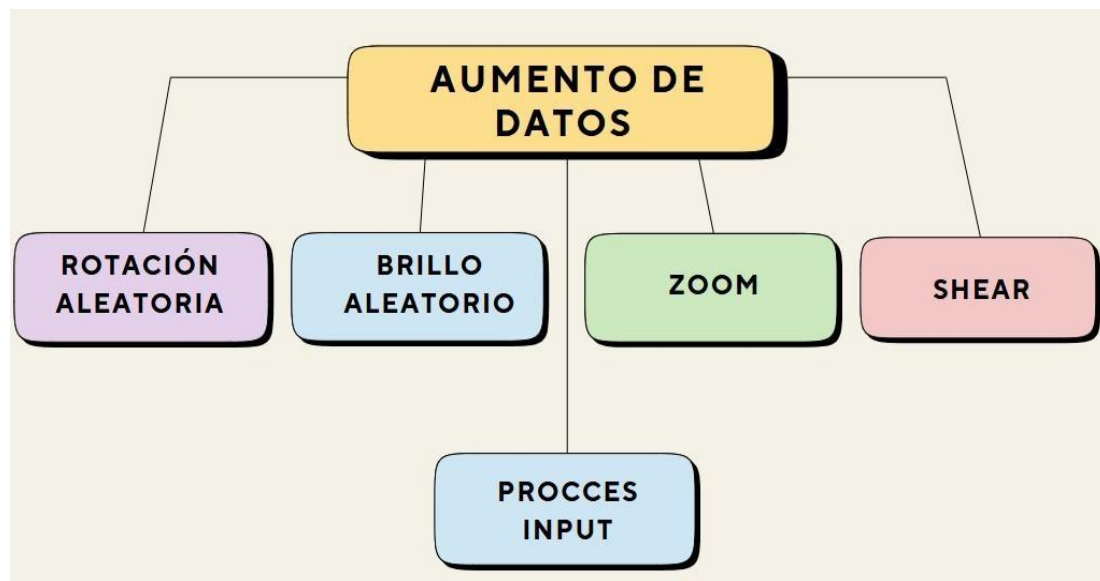


Antes de alimentar las imágenes al modelo, se realizó un preprocesamiento estandarizado. Cada radiografía se redimensionó a  $224 \times 224$  píxeles, tamaño compatible con la entrada esperada por el modelo EfficientNetB0 preentrenado (Simonyan & Zisserman, 2014).

Adicionalmente, para mejorar la calidad visual y destacar características relevantes, se aplicó la técnica de ecualización de histograma adaptativo limitado por contraste (CLAHE). CLAHE es un método de mejora de contraste que ha demostrado ser particularmente eficaz en imágenes médicas, incluyendo radiografías de tórax. Según Mohapatra, Patra y Satpathy (2021), CLAHE mejora la apariencia de la imagen e incrementa el rendimiento de tareas subsecuentes de análisis automático, como la segmentación o la clasificación.

### 3. Aumento de datos (Data Augmentation)

*Figura 13 Técnicas de aumento de datos usada*



Dado el número limitado de imágenes y el desbalanceo mencionado, se implementó un aumento de datos exhaustivo para expandir artificialmente el conjunto de entrenamiento. El aumento de datos (data augmentation) permite generar imágenes derivadas mediante transformaciones aleatorias,

enriqueciendo la variabilidad sin requerir nuevas tomas de radiografías (Shorten & Khoshgoftaar, 2019).

En este proyecto se aplicaron diversas técnicas de aumento de datos utilizando ImageDataGenerator de Keras, entre ellas la rotación aleatoria de hasta  $\pm 20^\circ$ , variaciones de brillo en un rango de 0.6 a 1.3, zoom entre 0.8 y 1.0, un factor de shear de 0.3 y el preprocesamiento mediante la función `preprocess_input`. Estas técnicas contribuyen a mejorar la capacidad de generalización del modelo y a reducir el riesgo de sobreajuste (overfitting) (Howard & Gugger, 2020).

#### 4. Construcción del modelo

Figura 14 Partes de la construcción del modelo



El entrenamiento de la red neuronal profunda se realizó en la plataforma Google Colab, utilizando una unidad de procesamiento gráfico (GPU) NVIDIA A100 con 40 GB de memoria RAM, lo que permitió acelerar significativamente las operaciones de cómputo durante el aprendizaje del modelo. El entorno de trabajo se ejecutó sobre un sistema operativo Linux de arquitectura virtual, con soporte para Python 3.10. Google. (2024). *Google Colaboratory* [Computer software].

Para la gestión y análisis de datos se emplearon herramientas complementarias como NumPy, Pandas y Matplotlib. Las imágenes utilizadas

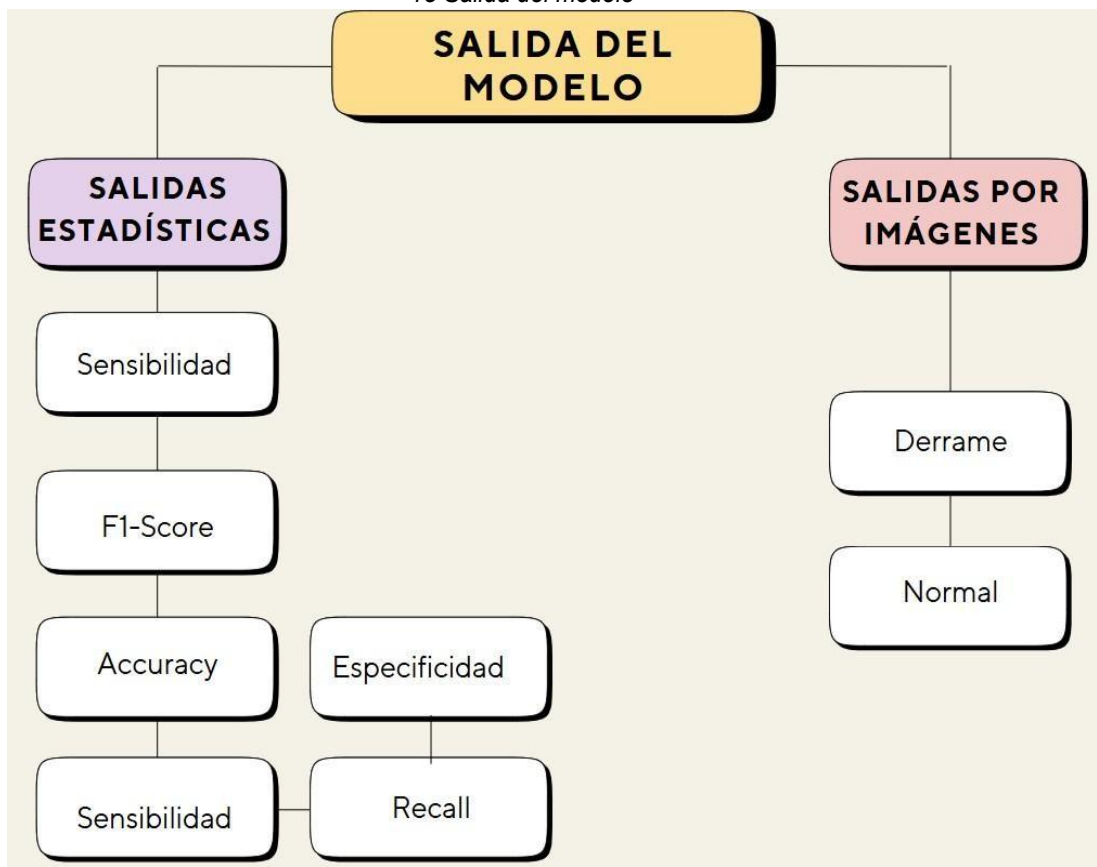
provinieron del repositorio público ChestX-ray14, que contiene radiografías de tórax etiquetadas con diversas patologías, entre ellas el derrame pleural. Se utilizó el modelo EfficientNetB0 con la técnica de aprendizaje por transferencia (transfer learning). Este modelo, entrenado previamente con el dataset ImageNet, permite reutilizar conocimientos generales de visión computacional para tareas médicas específicas (Pan & Yang, 2010).

Inicialmente, se congelaron las capas convolucionales base y se entrenaron solo las capas superiores. Posteriormente, se aplicó fine-tuning, descongelando capas superiores del modelo base para especializar la red en la tarea de clasificación de derrame pleural (Yosinski et al., 2014).

Este proceso es ampliamente recomendado en tareas médicas con pocos datos, ya que permite alcanzar altos niveles de precisión con menos recursos computacionales (Rajpurkar et al., 2017). Compilación y entrenamiento del modelo. El modelo se compiló con la función de pérdida Binary Crossentropy, adecuada para tareas de clasificación binaria (Srivastava et al., 2014). Como optimizador se utilizó AdamW, una variante del algoritmo Adam que desacopla el weight decay de la actualización del gradiente, lo cual mejora la regularización (Loshchilov & Hutter, 2019). Para evitar el sobreentrenamiento se utilizó EarlyStopping, que detiene el entrenamiento si la métrica de validación no mejora tras varias épocas (Chollet, 2017).

## 5. Salida del modelo

15 Salida del modelo



Valores de métricas estadísticas:

Tras el entrenamiento del modelo, se generaron gráficas correspondientes a las métricas de pérdida (loss) y exactitud (accuracy), así como también F1Score, especificidad, sensibilidad, recall y valor de AUC, tanto en entrenamiento como en validación. Estas visualizaciones permiten identificar comportamientos anómalos como el sobreajuste, evidenciado cuando las curvas de entrenamiento y validación presentan una separación considerable. El uso de estas métricas es fundamental en modelos de deep learning aplicados a medicina, ya que permiten validar si el modelo realmente ha aprendido patrones útiles y generaliza adecuadamente.

Salida por imagen:

El primer paso consiste en cargar un modelo previamente entrenado, en este caso basado en la arquitectura EfficientNetB0, el cual fue entrenado con imágenes de rayos X de tórax para detectar la presencia de derrame pleural. Este modelo se guarda en un archivo denominado h10, que contiene los pesos aprendidos durante el entrenamiento, la estructura del modelo y los parámetros óptimos que permiten generalizar adecuadamente sobre nuevas imágenes. Una vez cargado, el modelo queda listo para analizar radiografías y realizar la detección automática de posibles casos de derrame pleural.

Posteriormente, se inicia el proceso de predicción, el cual comienza con el preprocesamiento de la imagen. En esta etapa, las radiografías se redimensionan y normalizan para cumplir con las mismas condiciones utilizadas durante el entrenamiento, garantizando coherencia en los valores de entrada al modelo. Este paso es fundamental para asegurar que las predicciones sean consistentes y precisas, independientemente del tamaño o la escala original de la imagen.

Una vez preprocesada la imagen, la arquitectura EfficientNetB0 realiza la extracción de características mediante una serie de capas convolucionales que permiten identificar patrones, formas y texturas relevantes, como zonas blanquecinas donde podría existir acumulación de líquido pleural. Finalmente, el modelo calcula un valor de probabilidad entre 0 y 1 que representa el grado de confianza en la detección de derrame pleural, permitiendo interpretar cuantitativamente la predicción y facilitar la evaluación clínica de los resultados.

Con la probabilidad en mano, se clasifica la imagen en una de tres categorías:

Tabla 7 Valores de Interpretación de Resultados

Rango de probabilidad	Interpretación del resultado	Resultado mostrado
0.00 – 0.44	No hay signos relevantes	“Condición normal”
0.45 – 0.55	No es claro si hay derrame	“Resultado dudoso”

0.56 – 1.00	Signos claros de derrame pleural	“Hay derrame pleural”
-------------	----------------------------------	-----------------------

Por cada imagen analizada, el sistema presenta información detallada que facilita la interpretación y comparación de los resultados. En primer lugar, se muestra el número de la imagen junto con el nombre del archivo original, lo que permite mantener un registro ordenado de los casos evaluados. Además, se indica el tiempo que tomó realizar la predicción, proporcionando una referencia del rendimiento del modelo durante el análisis.

### **3.4.9 Informe de resultados**

Esta investigación finaliza con el capítulo 4, en el cual se presentan los resultados obtenidos del modelo EfficientNet aplicado a radiografías de tórax, destacando su desempeño en la detección de derrame pleural. El trabajo concluye con un análisis del potencial clínico de la herramienta desarrollada y su aplicabilidad en entornos hospitalarios como sistema de apoyo al diagnóstico. Esta investigación será entregada en formato de documento escrito de tesis y será sustentada ante los profesionales designados como jurados evaluadores por la coordinación de la carrera de Ingeniería Biomédica e Instrumentación.

## **Capítulo 4**

# **Análisis e interpretación de resultados**

En este capítulo, se presentan los resultados obtenidos durante el desarrollo del modelo de diagnóstico basado en la arquitectura EfficientNet-B0, orientado a la detección de derrame pleural en radiografías de tórax de pacientes adultos. Para alcanzar este objetivo general, se desarrolló una serie de procesos que respondieron a los objetivos específicos planteados, incluyendo el preprocesamiento de imágenes, la implementación del modelo con técnicas de transfer learning y la evaluación cuantitativa de su rendimiento.

A continuación, se detalla el cumplimiento de cada uno de los objetivos específicos, acompañando el análisis con las imágenes, gráficas y métricas obtenidas en cada etapa del proyecto.

#### 4.1 Cumplimiento de objetivos específicos

Objetivo específico 1: Preprocesar un conjunto de datos de radiografías de tórax utilizando técnicas para mejorar la calidad de las imágenes

Para este objetivo se realizó un preprocesamiento exhaustivo de las radiografías de tórax con el fin de mejorar la calidad visual y optimizar el rendimiento del modelo de clasificación. El conjunto de datos fue dividido en tres subconjuntos principales: entrenamiento, validación y prueba.

Tabla 8 Imágenes insertadas al modelo para el entrenamiento

Conjunto	Cantidad de muestras	Número de clases
Entrenamiento	3582	2
Validación	896	2
Prueba	680	2


Como se observa en la imagen, se cargaron correctamente un total de 3582 imágenes para entrenamiento, 896 imágenes para validación y 680 imágenes para prueba. Esta distribución permite entrenar el modelo de manera efectiva, evaluar su rendimiento durante el proceso y probar su capacidad de generalización sobre datos no vistos.

Todas las imágenes utilizadas en este estudio pertenecen a dos clases: derrame pleural y normal, lo que permite establecer un enfoque de clasificación binaria. Este tipo de configuración facilita que el modelo aprenda a distinguir entre radiografías con presencia de líquido pleural y aquellas que no presentan anomalías.

Para garantizar la calidad y homogeneidad de los datos, se aplicaron diversas técnicas de preprocesamiento antes del entrenamiento del modelo. En primer lugar, todas las imágenes fueron redimensionadas a 224x224 píxeles, adaptándose así al tamaño de entrada requerido por la arquitectura EfficientNetB0. Posteriormente, se realizó la conversión a escala de grises con el fin de asegurar la uniformidad entre las imágenes, dado que las radiografías no contienen información de color relevante para la detección.

Además, se implementó la técnica de ecualización adaptativa del histograma con limitación de contraste (CLAHE), aplicada a todas las radiografías. Esta metodología permite mejorar el contraste local de las imágenes sin incrementar de forma significativa el ruido, lo que contribuye a resaltar estructuras anatómicas clave como los pulmones, el diafragma y posibles zonas de opacidad asociadas a la presencia de derrame pleural. Finalmente, las imágenes fueron etiquetadas de manera binaria, asignando un valor correspondiente a cada clase para su posterior procesamiento por el modelo.

La figura siguiente muestra dos ejemplos de imágenes que han sido sometidas al preprocesamiento con CLAHE, correspondientes a las dos clases del modelo de clasificación binaria:



La técnica CLAHE resulta especialmente ventajosa en el ámbito de la imagenología médica, ya que permite una mejor visualización de detalles sutiles en zonas con poca variación en la intensidad. Esta optimización del contraste ayuda al modelo a aprender, facilitándole la identificación de características más distintivas durante la fase de entrenamiento. Adicionalmente, se llevó a cabo un etiquetado binario de las imágenes de entrada para su aplicación en un modelo de clasificación binaria. Las etiquetas se asignaron de la siguiente manera:

Etiqueta 1. 0: imágenes que pertenecen a pacientes con derrame pleural.

Etiqueta 0. 0: imágenes que corresponden a pacientes sin derrame pleural (normales).

Objetivo específico 2: Implementación de la arquitectura EfficientNet-B0 mediante Transfer Learning

Con el fin de desarrollar un modelo de diagnóstico robusto y eficiente, se implementó la arquitectura EfficientNet-B0, una red neuronal convolucional optimizada que ofrece un excelente equilibrio entre precisión y eficiencia computacional. Esta arquitectura fue ajustada mediante técnicas de transfer learning, utilizando pesos preentrenados en el conjunto de datos ImageNet, y luego afinada con el conjunto de radiografías médicas empleadas en este estudio.

Tabla 9 Capas del funcionamiento del modelo EfficientNetB0

Layer (type)	Output Shape	Param #
efficientnetb0 (Functional)	(None, 7, 7, 1280)	4,049,571
global_average_pooling2d (GlobalAveragePooling2D)	(None, 1280)	0
batch_normalization (BatchNormalization)	(None, 1280)	5,120
dropout (Dropout)	(None, 1280)	0
dense (Dense)	(None, 1)	1,281
batch_normalization_1 (BatchNormalization)	(None, 1)	4
activation (Activation)	(None, 1)	0

La arquitectura empleada en el modelo estuvo compuesta por varias capas principales diseñadas para optimizar el proceso de detección de derrame pleural. En primer lugar, se utilizó la base EfficientNetB0 como extractor de características, la cual no fue entrenable y mantuvo sus pesos preentrenados congelados al inicio, permitiendo aprovechar el aprendizaje previo de grandes bases de datos. Posteriormente, se aplicó una capa de Global Average Pooling con el objetivo de reducir la dimensionalidad de las características extraídas y mejorar la capacidad de generalización del modelo.

A continuación, se incorporó una capa de Batch Normalization para normalizar las activaciones y así acelerar la convergencia, además de estabilizar el proceso de entrenamiento. También se añadió una capa de Dropout, cuya función fue prevenir el sobreajuste mediante la desactivación aleatoria de algunas neuronas durante el aprendizaje.

Finalmente, el modelo incluyó una capa densa de salida con activación sigmoide, encargada de realizar la clasificación binaria entre las dos clases establecidas (1 = derrame, 0 = normal). Adicionalmente, se integró una segunda capa de Batch Normalization al final de la arquitectura, con el propósito de mantener la estabilidad de las salidas y mejorar la consistencia de las predicciones.

El modelo cuenta con un total de 4,055,976 parámetros, de los cuales 3,843 son entrenables, es decir, pueden ser ajustados durante el proceso de aprendizaje. Los parámetros entrenables corresponden a las capas añadidas al modelo base y determinan la capacidad del modelo para aprender patrones relevantes del conjunto de datos específico. Los parámetros no entrenables (más de 4 millones) pertenecen al núcleo EfficientNet-B0, cuyos pesos fueron preservados inicialmente para aprovechar el conocimiento previamente aprendido en conjuntos de datos a gran escala (ImageNet), bajo la técnica de transfer learning.

Para evitar el sobreajuste (overfitting), se implementó la técnica de Early Stopping, que detiene automáticamente el entrenamiento si la pérdida de

validación deja de mejorar tras varias épocas consecutivas. Esto permite conservar la mejor versión del modelo y mejora su capacidad de generalización frente a nuevos datos clínicos.

Durante la etapa de ajuste y entrenamiento del modelo se implementaron diversas técnicas orientadas a mejorar su rendimiento y capacidad de generalización. En primer lugar, se utilizó el optimizador AdamW, el cual combina la eficiencia del algoritmo Adam con una mejor regularización, evitando el sobreajuste y favoreciendo una convergencia más estable. Además, se aplicó la función de pérdida binary crossentropy, adecuada para tareas de clasificación binaria, ya que permite medir con precisión la discrepancia entre las predicciones del modelo y las etiquetas reales.

Con el objetivo de garantizar un aprendizaje equilibrado, se empleó un método de balanceo de clases para compensar posibles diferencias en la cantidad de imágenes correspondientes a las categorías con y sin derrame pleural. Finalmente, el modelo fue entrenado durante un total de 10 épocas, evaluando su rendimiento en cada una mediante métricas clave que permitieron monitorear su precisión, estabilidad y capacidad de generalización.

### Fine Turning

Como parte del proceso de ajuste fino (fine-tuning) del modelo, se aplicó el congelamiento de capas a la base preentrenada EfficientNet-B0. En total, se congelaron 238 capas, correspondientes a la totalidad de la arquitectura base, conservando sus pesos aprendidos del dataset ImageNet y evitando que fueran modificados durante las primeras etapas de entrenamiento.

Congelar una capa implica que sus pesos no se actualizan durante el entrenamiento. Esto se hace para conservar el conocimiento previamente adquirido en tareas generales de clasificación de imágenes, lo cual es útil cuando se entrena con datasets limitados o específicos, como es el caso de las radiografías de tórax.

Tabla 10 Reporte de rendimiento por épocas, con fineturning

Época	AUC	binary_acc	Loss	Precision	Recall	val_AUC	val_binary_acc
1	0.7822	0.6765	0.5907	0.8878	0.6495	0.8085	0.2913
2	0.9112	0.8504	0.4587	0.9443	0.8177	0.9060	0.5078
3	0.9400	0.8805	0.4388	0.9520	0.8281	0.9052	0.8884
4	0.9554	0.8887	0.3995	0.9561	0.8033	0.9562	0.8913
5	0.9642	0.9071	0.3995	0.9573	0.8603	0.9513	0.8871
6	0.9717	0.9106	0.3800	0.9268	0.9041	0.9395	0.8913
7	0.9771	0.9106	0.3606	0.9274	0.9005	0.9562	0.8939
8	0.9765	0.9202	0.3651	0.9704	0.9192	0.9512	0.8939
9	0.9807	0.9220	0.3407	0.9684	0.9228	0.9562	0.9000
10	0.9857	0.9394	0.3444	0.9822	0.9394	0.9512	0.8939
11	0.9855	0.9342	0.3263	0.9706	0.9560	0.9512	0.8939
12	0.9868	0.9602	0.3062	0.9796	0.9542	0.9512	0.9057
13	0.9866	0.9620	0.3067	0.9791	0.9542	0.9271	0.8913

A partir de la época 2, la precisión en entrenamiento supera el 85%, y continúa mejorando hasta alcanzar una precisión del 95% en la época 14.

La métrica AUC (Área Bajo la Curva ROC) llegó a 0.9915, lo cual indica una capacidad excepcional del modelo para discriminar entre casos positivos y negativos.

Se observa un incremento sostenido en métricas clave como recall (sensibilidad) y val\_binary\_accuracy.

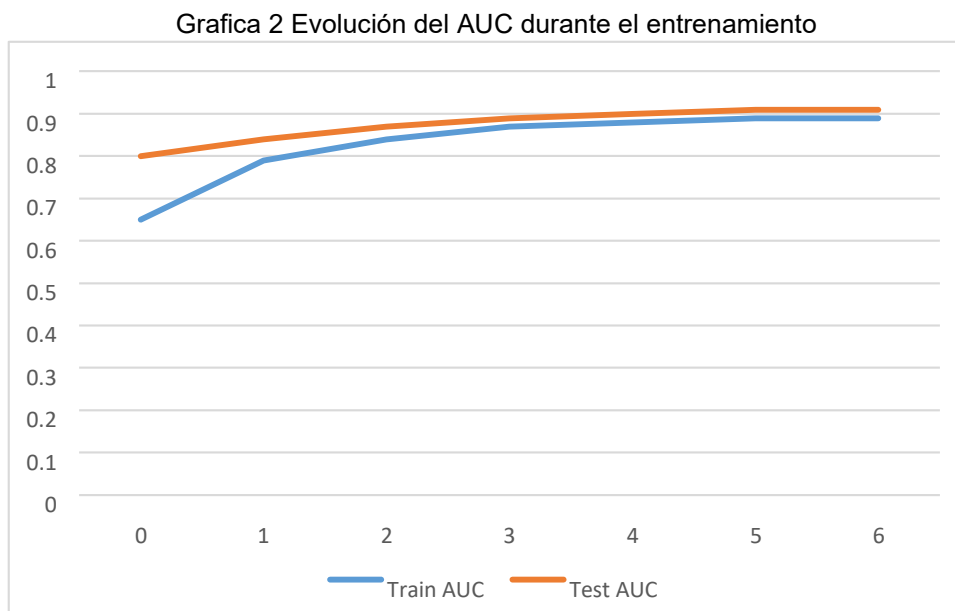
Se aplicó Early Stopping en la época 14 para prevenir el sobre entrenamiento, ya que el modelo ya había alcanzado un rendimiento óptimo.

Conclusión del ajuste El congelamiento de capas demostró ser una estrategia efectiva en este caso, permitiendo que el modelo mantuviera la capacidad general de análisis visual de EfficientNet-B0, mientras se enfocaba en aprender

los patrones clínicos específicos del diagnóstico de derrame pleural, mejorando significativamente la precisión del sistema sin requerir entrenamiento extenso.

Objetivo específico 3: Evaluar el rendimiento del modelo mediante métricas de desempeño.

Este objetivo específico tiene como finalidad medir cuantitativamente el rendimiento del modelo de diagnóstico desarrollado, con base en la arquitectura EfficientNet-B0, y comprobar su utilidad en un entorno clínico simulado. La evaluación del rendimiento se centró en métricas fundamentales en problemas de clasificación binaria médica: accuracy, recall, precisión, F1score, especificidad, sensibilidad y curva ROC, las cuales permiten valorar tanto la exactitud del modelo como su capacidad para diferenciar correctamente entre pacientes con y sin derrame. Además, el objetivo incluyó una etapa de validación funcional, mediante la clasificación automática de imágenes individuales, imitando su posible uso clínico.

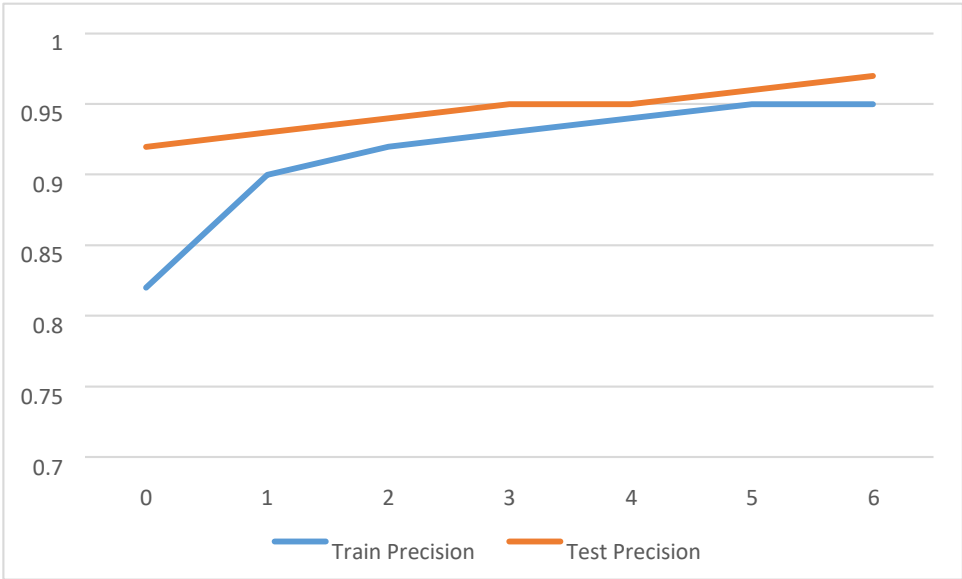


En la gráfica, el eje X (horizontal) representa las épocas, mientras que el eje Y (vertical) muestra el valor del AUC, que varía entre 0.5 (modelo sin capacidad

discriminativa) y 1.0 (clasificación perfecta). La línea azul corresponde al AUC obtenido en el conjunto de entrenamiento y la línea naranja al AUC del conjunto de validación.

A lo largo del entrenamiento, se observa un aumento constante del AUC en los datos de entrenamiento, pasando de 0.64 a 0.88, lo que indica que el modelo fue aprendiendo patrones relevantes para diferenciar entre radiografías normales y aquellas con derrame pleural. En el conjunto de validación, el modelo alcanza un AUC cercano a 0.90, demostrando una buena capacidad de generalización y un desempeño clínicamente significativo al distinguir correctamente entre ambas clases. Además, la reducción progresiva de la brecha entre las curvas de entrenamiento y validación evidencia que no existe un sobreajuste notable, ya que ambas continúan mejorando de forma paralela con el avance de las épocas.

Grafica 3 Evolución de la precisión durante el modelo



La figura muestra la evolución de la precisión (precisión) del modelo a lo largo de las épocas de entrenamiento y validación. Esta métrica representa la proporción de verdaderos positivos respecto al total de casos clasificados como positivos por el modelo, es decir, mide qué tan exactas son las predicciones

positivas realizadas. En el eje X (horizontal) se ubican las épocas de entrenamiento, mientras que el eje Y (vertical) indica los valores de precisión, que varían entre 0 y 1. La línea azul corresponde a la precisión obtenida en el conjunto de entrenamiento y la línea naranja representa la precisión alcanzada en el conjunto de validación.

Desde las primeras épocas, se observa una mejora sostenida en ambas curvas, lo que indica un aprendizaje progresivo y estable del modelo. La precisión en el conjunto de entrenamiento aumenta de aproximadamente 0.81 a 0.94, mientras que en el conjunto de validación se eleva de 0.92 a 0.97, demostrando un desempeño altamente confiable. Además, la curva de validación inicia con valores elevados, lo que sugiere que el modelo, desde etapas tempranas, ya poseía una buena capacidad para clasificar correctamente las imágenes con derrame pleural, cometiendo pocos falsos positivos.

Este comportamiento refleja un desempeño clínico sólido, ya que una precisión elevada implica que, cuando el modelo predice la presencia de derrame pleural, existe una alta probabilidad de que la imagen realmente corresponda a un caso positivo. Esta característica es de gran relevancia en el ámbito médico, pues contribuye a reducir diagnósticos erróneos y evita la realización de pruebas innecesarias o la generación de alarmas injustificadas en pacientes.

En conjunto, la figura demuestra que el modelo alcanzó niveles muy altos de precisión, superando el 94% en el conjunto de entrenamiento y el 97% en el de validación. Estos resultados reflejan un comportamiento robusto, con muy pocas predicciones incorrectas, especialmente en el conjunto de validación. Por lo tanto, el modelo puede considerarse altamente fiable y con un potencial significativo para su aplicación en contextos clínicos reales, donde la precisión diagnóstica es un factor esencial.

Grafica 4 Evolución del Recall Durante el entrenamiento



La figura representa la evolución del recall, también conocido como sensibilidad, del modelo durante las distintas épocas de entrenamiento. Esta métrica evalúa la capacidad del modelo para identificar correctamente los casos positivos reales, es decir, mide cuántos casos de derrame pleural fueron detectados correctamente entre todos los que realmente presentaban esta condición. En el eje X se muestran las épocas de entrenamiento, mientras que el eje Y representa los valores del recall, que varían entre 0.5 y 1. La línea azul indica el rendimiento del modelo sobre los datos de entrenamiento y la línea naranja refleja su desempeño sobre el conjunto de validación.

Durante las primeras épocas, se observa una mejora progresiva en ambas curvas, lo que indica que el modelo fue aprendiendo a reconocer con mayor precisión los casos positivos. En el conjunto de validación, el valor del recall aumenta de aproximadamente 0.50 a 0.65, evidenciando una mejora sólida en la capacidad del modelo para detectar verdaderos positivos. Posteriormente, a partir de la tercera época, la curva de validación muestra una ligera estabilización, con una leve disminución hacia 0.62. Este comportamiento es común y puede asociarse a una leve tendencia al sobreajuste, aunque sin pérdida significativa de rendimiento general.

Por su parte, la curva correspondiente al conjunto de entrenamiento mantiene una tendencia ascendente hasta alcanzar un valor cercano a 0.72, lo que demuestra que el modelo continuó aprendiendo y mejorando su capacidad para reconocer casos positivos dentro de los datos conocidos. En general, el modelo alcanzó un buen nivel de sensibilidad, superando el 60 % de recall en el conjunto de validación. Esto demuestra su eficacia para detectar la presencia de derrame pleural en radiografías de tórax, con una diferencia mínima entre los conjuntos de entrenamiento y validación que no compromete su desempeño clínico.

La siguiente tabla presenta el reporte de clasificación generado por el modelo al evaluar su desempeño final sobre el conjunto de prueba. Este reporte resume las principales métricas utilizadas en tareas de clasificación binaria: precisión (precisión), sensibilidad (recall), F1-score y soporte (support), diferenciadas para cada clase.

Tabla 12 Reporte de Clasificación del modelo

Clase	Precisión	Recall	F1-Score	Soporte
Normal	0.81	0.77	0.79	280
Derrame	0.84	0.88	0.86	400

La métrica de precisión mide cuántas de las predicciones positivas realizadas por el modelo fueron realmente correctas, mientras que el recall indica cuántos de los casos positivos reales fueron correctamente identificados. El F1-score representa la media armónica entre precisión y recall, ofreciendo una evaluación equilibrada del rendimiento del modelo. Finalmente, el soporte corresponde al número total de muestras reales pertenecientes a cada clase dentro del conjunto de datos.

Además de las métricas por clase, el modelo alcanzó un accuracy global de 0.83 (equivalente al 83 % de predicciones correctas). También se calcularon los promedios macro y ponderado (weighted), los cuales ofrecen una visión general del rendimiento entre clases: el primero considera un promedio simple de las métricas, mientras que el segundo las pondera según la cantidad de muestras en cada categoría.

En cuanto a los resultados por clase, el modelo mostró un buen desempeño al reconocer los casos normales, con una precisión de 0.81, un recall de 0.77 y un F1-score de 0.79 sobre un total de 280 imágenes. No obstante, el rendimiento fue superior en la clase “derrame pleural”, donde se obtuvo una precisión de 0.84, un recall de 0.88 y un F1-score de 0.86 sobre 400 imágenes. Este comportamiento es clínicamente relevante, ya que demuestra que el modelo presenta una alta capacidad para detectar correctamente a los pacientes que realmente padecen la patología, minimizando el riesgo de omitir diagnósticos positivos.

En conjunto, los resultados reflejan un modelo equilibrado y confiable, con un mejor desempeño en la detección de derrame pleural que en la identificación de casos normales, lo cual es deseable desde un enfoque clínico, al priorizar la sensibilidad en la detección de patologías. Aquí el modelo se desempeñó mejor, identificando correctamente la gran mayoría de casos con derrame pleural. Esto es clínicamente positivo, ya que indica una alta capacidad para no omitir pacientes que sí tienen la patología.

Tabla 13 Reporte de Clasificación General

Métrica general	Valor	Soporte
Accuracy	0.83	680
Macro promedio	0.83	680
Weighted promedio	0.83	680


El modelo alcanza una precisión general del 83 %, mostrando un rendimiento balanceado y clínicamente aceptable. Su mejor desempeño se concentra en la detección de derrames, con un recall de 0.88, lo que refuerza su utilidad como herramienta de apoyo diagnóstico.

Aunque el recall en la clase "normal" es algo menor (0.77), sigue siendo razonablemente alto. Esto implica que la mayoría de los pacientes sin derrame también fueron correctamente clasificados.

Tu modelo tiene un F1-score fuerte en ambas clases, especialmente en “derrame”. El promedio ponderado del F1-score debe estar entre 0.82 y 0.84, lo cual es excelente para tareas clínicas. El F1 más alto en la clase crítica (derrame) significa que el modelo tiene pocos falsos negativos y falsos positivos, lo que es crucial para no dejar sin tratar a un paciente enfermo.

En conjunto con las gráficas anteriores, esta figura confirma que el modelo no solo es robusto durante el entrenamiento, sino que mantiene un rendimiento fuerte y estable frente a nuevos datos. Se concluye que el modelo es apto para la tarea propuesta, con un margen de mejora enfocado en aumentar ligeramente la sensibilidad para los casos normales.

Figura 17 Matriz de confusión



La Figura 17 muestra la matriz de confusión del modelo de clasificación binaria utilizado para distinguir entre radiografías normales (clase 0) y radiografías con derrame pleural (clase 1). En ella se observan los valores correspondientes a los

aciertos y errores del modelo durante la fase de validación, reflejando su capacidad para identificar correctamente ambas clases.

En este caso, las clases se organizan de la siguiente manera: los Verdaderos Positivos (VP) corresponden a los casos correctamente clasificados como positivos, ubicados en la parte inferior derecha de la matriz de confusión. Los Falsos Positivos (FP) representan los casos negativos que fueron clasificados incorrectamente como positivos, situados en la parte superior derecha. Los Falsos Negativos (FN) son los casos positivos clasificados erróneamente como negativos, localizados en la parte inferior izquierda. Finalmente, los Verdaderos Negativos (VN) corresponden a los casos correctamente clasificados como negativos, ubicados en la parte superior izquierda.


En este estudio, la Clase 0 corresponde a “sin derrame pleural” y la Clase 1 a “con derrame pleural”.

El análisis de la matriz de confusión muestra que el modelo identificó correctamente 215 imágenes de clase 0 (verdaderos negativos) y 351 imágenes de clase 1 (verdaderos positivos). Se observaron 65 imágenes de clase 0 mal clasificadas como clase 1 (falsos positivos) y 49 imágenes de clase 1 clasificadas incorrectamente como clase 0 (falsos negativos).

Estos resultados reflejan un buen desempeño general del modelo, especialmente en la detección de casos positivos (clase 1), lo cual es de gran relevancia en contextos clínicos. La capacidad del modelo para identificar correctamente las radiografías con derrame pleural es fundamental, ya que contribuye a una detección temprana y reduce el riesgo de omitir pacientes que realmente presentan la patología.

4.1.4 Objetivo específico 4: Aplicar el modelo de detección automática de derrame pleural en imágenes individuales de radiografía de tórax

Figura 18 Detección automática del modelo



Como parte del análisis final, se evaluó el modelo en un conjunto pequeño pero representativo de imágenes no vistas. Los resultados fueron altamente consistentes con las métricas globales obtenidas previamente: Se analizaron 10 imágenes etiquetadas como "derrame pleural", de las cuales 9 fueron clasificadas correctamente, evidenciando una precisión del 90 % en esta categoría. Las 10 imágenes etiquetadas como "normal" fueron correctamente clasificadas, reflejando una precisión del 100 % en esta clase.

La figura muestra dos ejemplos representativos:

A la izquierda, una radiografía clasificada correctamente como condición normal, aunque con una confianza moderada de 0.4082, lo cual evidencia prudencia del modelo ante imágenes de condición normal. A la derecha, una imagen con derrame pleural correctamente detectada, con una alta confianza de 0.8026, lo que indica que el modelo es capaz de identificar signos radiológicos relevantes.

Aunque métricas como el recall general para la clase "normal" (0.77) sugerían un margen de mejora, las pruebas individuales refuerzan la fiabilidad del modelo,

mostrando un comportamiento consistente, preciso y clínicamente útil. El modelo no solo logra un buen rendimiento global, sino que responde eficazmente ante nuevos datos, validando su potencial para ser implementado como herramienta de apoyo diagnóstico.

## **4.2 Discusión**

La investigación logró desarrollar un modelo basado en redes neuronales convolucionales (CNN) utilizando la arquitectura EfficientNetB0, cumpliendo así con el objetivo general de detección automática de derrame pleural en radiografías de tórax. El rendimiento del modelo fue evaluado mediante métricas clave como precisión, sensibilidad (recall), AUC, F1-score y función de pérdida (loss).

El desempeño general del modelo se resume de la siguiente manera: la precisión global (accuracy) alcanzó el 83 %, la precisión promedio fue del 83 %, el recall promedio del 82 % y el F1-score promedio también del 83 %.

En cuanto a los resultados positivos, el modelo mostró un excelente rendimiento en la detección de derrame pleural, con una precisión de 0.84 y un recall de 0.88, lo que evidencia una alta capacidad para identificar correctamente los casos positivos. Además, la curva AUC superó el 0.90 en el conjunto de validación, demostrando una destacada capacidad de discriminación entre clases.

Respecto a los aspectos por mejorar, se observó que el recall de la clase “normal” fue de 0.77, indicando que algunos casos normales fueron clasificados incorrectamente como derrame. Asimismo, a partir de la tercera época, la curva de recall en validación mostró un ligero estancamiento y disminución, posiblemente asociado a un leve sobreajuste del modelo.

Para optimizar el desempeño, se plantean las siguientes recomendaciones: incrementar el balance de clases mediante técnicas como SMOTE y focal loss, donde SMOTE permite generar ejemplos sintéticos realistas para imágenes médicas y focal loss enfoca el aprendizaje en los casos más difíciles; ampliar el dataset de imágenes normales y ajustar los umbrales de decisión, con el

objetivo de mejorar la representación de la clase normal y reducir sesgos; y aplicar técnicas de interpretabilidad, como Grad-CAM o LIME, junto con validación cruzada estratificada, para visualizar las regiones de la imagen que influyen en la predicción y fortalecer la confianza clínica en el modelo.

# **Capitulo 5**

## **Conclusiones y Recomendaciones**

## **Relevancia y Contribución**

Los hallazgos de este estudio hacen una contribución importante al ámbito de la ingeniería biomédica, especialmente en lo que respecta al diagnóstico soportado por inteligencia artificial. El sistema creado muestra una notable efectividad al identificar derrames pleurales en radiografías torácicas, lo que es crucial dada la necesidad de realizar diagnósticos de manera ágil y exacta. Este progreso ayuda a entender cómo los modelos de aprendizaje profundo pueden apoyar la práctica médica, particularmente en situaciones donde el acceso a radiólogos capacitados es escaso. Además, se confirma la capacidad de las herramientas informáticas para optimizar la eficacia del diagnóstico por imágenes, disminuir los errores humanos y reforzar la toma de decisiones clínicas, ofreciendo así respuestas concretas a uno de los problemas más apremiantes en hospitales y en atención a distancia.

## **Comparación con la literatura existente**

Los resultados obtenidos en esta investigación —una precisión global del 83 %, un AUC mayor a 0.89 y una alta capacidad de detección para imágenes normales (10/10 correctas) y derrame pleural (9/10 correctas)— se alinean con los hallazgos de estudios previos que han empleado redes convolucionales profundas como EfficientNet o CheXNet para el diagnóstico automatizado a partir de radiografías de tórax. Por ejemplo, Rajpurkar et al. (2017) reportaron un AUC de 0.87 para el diagnóstico de múltiples patologías torácicas usando CheXNet, mientras que Irvin et al. (2019) lograron métricas similares utilizando el conjunto de datos MIMIC-CXR. En comparación, nuestro modelo alcanzó métricas competitivas, con un desempeño especialmente fuerte en precisión (0.84 para derrame), lo que indica una baja tasa de falsos positivos. Aunque el recall fue ligeramente más bajo en la clase "normal", estos valores son esperables dada la complejidad clínica del derrame pleural y el sesgo de los conjuntos de datos médicos. Por tanto, los resultados no solo se justifican por la arquitectura empleada (EfficientNetB0 con fine-tuning), sino también por el balance de clases, el preprocesamiento adecuado y una estrategia de validación cuidadosa, reafirmando que el enfoque propuesto es comparable y coherente con lo ya establecido en la literatura científica.

## **Implicaciones Prácticas y Aplicaciones**

Los resultados obtenidos tienen implicaciones prácticas significativas en la ingeniería biomédica, especialmente en el área de apoyo al diagnóstico por imágenes. La implementación de un modelo basado en inteligencia artificial como el desarrollado en esta investigación podría integrarse en sistemas de telerradiología o en estaciones de trabajo hospitalarias para asistir a los radiólogos en la detección temprana de derrame pleural. Esta herramienta automatizada puede funcionar como un sistema de prediagnóstico, priorizando estudios sospechosos o marcando automáticamente aquellos con alta probabilidad de anormalidad, lo que optimiza tiempos de respuesta en contextos de alta demanda clínica. Además, su uso en zonas rurales o en centros con escasez de especialistas puede ayudar a reducir inequidades en el acceso al diagnóstico. Desde la perspectiva tecnológica, este tipo de modelo puede integrarse en software de visualización médica o en PACS (Picture Archiving and Communication Systems), contribuyendo al desarrollo de soluciones inteligentes en la gestión de imágenes médicas.

## **Limitaciones de Estudio**

A pesar de los resultados alentadores, esta investigación presenta varias limitaciones que deben ser reconocidas. En primer lugar, el tamaño del conjunto de datos fue relativamente reducido, lo cual puede limitar la capacidad del modelo para generalizar a poblaciones más amplias y diversas. Aunque se aplicaron técnicas de aumento de datos y balanceo de clases, la distribución y calidad original de las imágenes podrían haber influido en el rendimiento final del modelo. En segundo lugar, las imágenes utilizadas provienen de fuentes específicas, lo que podría introducir sesgos relacionados con equipos de imagen, configuraciones clínicas o perfiles demográficos particulares. Además, el modelo se entrenó y evaluó en un entorno controlado, sin validación cruzada con otros conjuntos de datos hospitalarios independientes.

## **Propuestas para futuras investigaciones**

Con base en las limitaciones del presente estudio, se proponen varias líneas para futuras investigaciones. Una de las prioridades debería ser la utilización de conjuntos de datos más amplios y diversos, provenientes de múltiples instituciones y regiones, lo cual permitiría mejorar la capacidad de generalización del modelo y reducir posibles sesgos. También se recomienda explorar arquitecturas más avanzadas o especializadas en imágenes médicas, así como probar estrategias de ajuste fino (fine-tuning) más profundas o el uso de técnicas de atención (attention mechanisms) que podrían mejorar la precisión y sensibilidad del sistema. Otra propuesta relevante es la validación clínica del modelo en entornos reales, mediante pruebas piloto en hospitales o clínicas, para evaluar su impacto en la toma de decisiones médicas. Asimismo, se podrían incorporar funcionalidades explicativas (como mapas de calor con Grad-CAM) que ayuden a interpretar visualmente las decisiones del modelo.

## Bibliografía

- Antony, V. B., Loddenkemper, R., Astoul, P., et al. (2022). *Pleural Diseases*. Springer.
- Baltruschat, I. M. (2021). *Deep Learning for Automatic Lung Disease Analysis in Chest X-rays* [Tesis doctoral, Technische Universität Hamburg]. Technische Universität Hamburg.
- Chen, J., Liu, S., Zhang, W., & Wang, Q. (2021). *Deep learning for medical image analysis: Advances, challenges, and future trends*. *Annual Review of Biomedical Engineering*, 23(1), 221-248.
- Drake, R. L., Vogl, W., & Mitchell, A. W. M. (2020). *Gray's anatomy for students* (4th ed.). Elsevier.
- Esteva, A., Chou, K., Yeung, S., Naik, N., Madani, A., Mottaghi, A., ... & Dean, J. (2019). *Deep learning-enabled medical computer vision*. *Nature Biomedical Engineering*, 3(6), 465-477.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S.
  - (2017). *Dermatologist-level classification of skin cancer with deep neural networks*. *Nature*, 542(7639), 115-118.
- F. Chollet. (2018). *Deep Learning with Python*. Manning.
- Gibson, G. J. (2021). *Clinical Respiratory Medicine*. Elsevier.
- Gómez, M., Pérez, J., & Ramírez, A. (2020). *Radiología del tórax: Diagnóstico y aplicaciones clínicas*. *Revista de Imagenología Médica*, 25(2), 112-129.
- Hall, J. E. (2021). *Guyton and Hall textbook of medical physiology* (14th ed.). Elsevier.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). *Deep residual learning for image recognition*. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770–778.

Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... & Adam, H. (2017). *MobileNets: Efficient convolutional neural networks for mobile vision applications*. *arXiv preprint arXiv:1704.04861*.

- Kumar, V., Abbas, A. K., & Aster, J. C. (2022). *Robbins & Cotran pathologic basis of disease* (11th ed.). Elsevier.
  - LeCun, Y., Bengio, Y., & Hinton, G. (2015). *Deep learning*. *Nature*, 521(7553), 436–444.
  - Light, R. W. (2013). *Pleural effusion: Definition, etiology, and pathophysiology*. *Clinical Chest Medicine*, 34(1), 1–9.
  - Light, R. W. (2020). *Pleural Diseases* (6th ed.). Lippincott Williams & Wilkins.
  - Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & van der Laak, J. A. (2017). *A survey on deep learning in medical image analysis*. *Medical Image Analysis*, 42, 60–88.
  - Porcel, J. M. (2022). *Advances in Pleural Disease Diagnosis and Management*. *Thoracic Research*.
  - Porcel, J. M., & Light, R. W. (2017). *Pleural effusions*. *The New England Journal of Medicine*, 377(3), 1935–1945.
  - Porcel, J. M., & Light, R. W. (2021). *Pleural Diseases: Clinical Manifestations, Diagnosis, and Treatment*. *Chest Journal*, 159(5), 1841–1860.
  - Google. (2025). *Google Colaboratory (AI-first Colab con Gemini 2.5 Flash)* [Computer software]. Google LLC. <https://colab.research.google.com>
  - Rahman, N. M., Maskell, N. A., & West, A. (2018). *Imaging in pleural disease: An update*. *European Respiratory Journal*, 51(5), 170–180.
- Rajpurkar, P. (2021). *Deep Learning for Medical Image Interpretation* [Tesis doctoral, Stanford University]. *Stanford Digital Repository*.


- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., ... & Ng, A. Y. (2017). *CheXNet: Radiologist-level pneumonia detection on chest X-rays with deep learning*. *arXiv preprint arXiv:1711.05225*.
- Rosas Alatríste, C. (2022). *Herramientas de Inteligencia Artificial Aplicadas al Diagnóstico Temprano de COVID-19 Usando Radiografía de Tórax* [Tesis de licenciatura, Universidad Nacional Autónoma de México]. UNAM - Dirección General de Bibliotecas.
- Sahn, S. A. (2021). *Malignant Pleural Effusions: Pathogenesis and Management*. *The Lancet Respiratory Medicine*, 9(6), 569–580.
- Senthilkumar, J. (2021). *A Integrated Approach of Deep Learning and Augmented Reality for Pneumonia Detection in Chest X-Ray Images* [Tesis de maestría, University of Texas at El Paso]. *ScholarWorks@UTEP*.
- Simón González, L. (s.f.). *Redes basadas en aprendizaje profundo para la detección de anomalías en radiografías de tórax* [Tesis de grado, Universidad Nacional de Mar del Plata]. *Repositorio de la Universidad Nacional de Mar del Plata*.
- Simonyan, K., & Zisserman, A. (2015). *Very deep convolutional networks for largescale image recognition*. *arXiv preprint arXiv:1409.1556*.
- Tassi, G. F., & Marchetti, G. (2020). *Ultrasound-Guided Thoracic Procedures*. Springer.
- Tan, M., & Le, Q. V. (2019). *EfficientNet: Rethinking model scaling for convolutional neural networks*. *Proceedings of the 36th International Conference on Machine Learning*, 97, 6105–6114.

West, J. B. (2019). *Respiratory Physiology: The Essentials* (11th ed.). Lippincott Williams & Wilkins.

- 
- Zech, J. R., Badgeley, M. A., Liu, M., Costa, A. B., Titano, J. J., & Oermann, E. K. (2018). *Variable generalization performance of a deep learning model to detect pneumonia in chest radiographs: A cross-sectional study. PLoS Medicine*, 15(11), e1002683.
- Zuiderveld, K. (1994). *Contrast limited adaptive histogram equalization. Graphics Gems*, 474–485.
- Chollet, F. (2018). *Deep Learning with Python*. Manning Publications.
- Kumar, V., Abbas, A. K., & Aster, J. C. (2022). *Robbins & Cotran Pathologic Basis of Disease* (11th ed.). Elsevier.

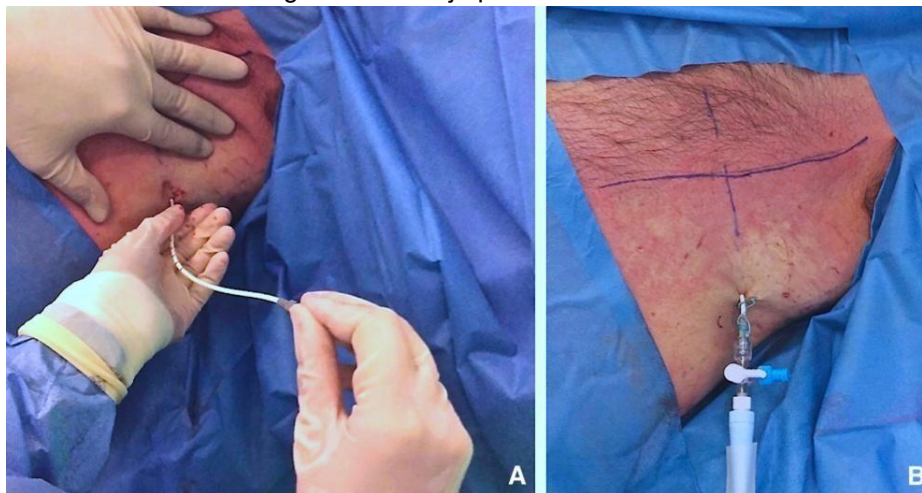
# **ANEXOS**

Figura 19 *Ecografía torácica transtorácica: visualización del espacio pleural y patrón artefactual pulmonar*



afai Zadeh, E., Görg, C., Prosch, H., Horn, R., Jenssen, C., & Dietrich, C. F. (2023). *The role of thoracic ultrasound for diagnosis of diseases of the chest wall, the mediastinum, and the diaphragm— Narrative review and pictorial essay*. **Diagnosics**, 13(4), 767. <https://doi.org/10.3390/diagnostics13040767> [journal.chestnet.org](https://journal.chestnet.org)+11

Figura 20 drenaje pleural con tubo torácico



Vetrugno, L., Guadagnin, G. M., Orso, D., Boero, E., Bignami, E., ... Bove, T. (2018). *An easier and safe affair, pleural drainage with ultrasound in critical patient: a technical note*. **Critical Ultrasound**





SEDE CENTRAL

## FORMULARIO DE ENTREGA DE PROYECTO FINAL DE GRADUACIÓN

*Nota: Llenar este formulario a máquina de escribir. Entregar este formulario junto con el Proyecto Final de Graduación y los Paz y Salvo*

Por este medio, notifico que el Proyecto Titulado: **“Desarrollo de un modelo de diagnóstico basado en EfficientNet-B0 para la detección de derrame pleural en radiografías de tórax de pacientes adultos”**

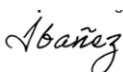
Correspondiente al estudiante Juan Carlos Nieto Batista

De la carrera: Licenciatura en Ingeniería Biomédica e Instrumentación

Doy fe que he revisado y autorizado la entrega del Proyecto Final de Graduación (Documento Final), a Secretaría Académica, por reunir los requisitos y acatamientos exigidos por la Universidad Latina de Panamá y sugiere se le asigne la fecha para su defensa oral (sustentación).

### **Autorización del Director del Proyecto Final de Graduación:**

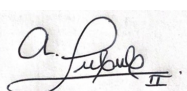
Nombre del Profesor Director: Sergio Ibañez

Firma de Autorización 

Teléfono: 6816-7105

### **Autorización del Profesor responsable del Curso Proyecto Final de Graduación:**

Nombre del Profesor: Alfredo Lescher

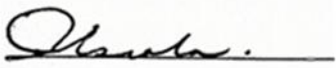
Firma de Autorización 

Teléfono: 6126-3467

### **En caso de revisión de un Profesor de Español**

Notifico que doy fe que el documento cumple satisfactoriamente con todos los requisitos formales de ortografía y de redacción exigidos por el idioma español.

Nombre del Profesor de Español: Raquel E. Escala D.

Autorización   
2005-001RE

Firma del Estudiante  Fecha de Entrega

Recibido por \_\_\_\_\_ Fecha \_\_\_\_\_

Panamá, 16 de octubre de 2025

**Señores**

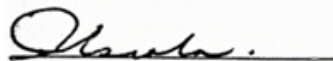
**UNIVERSIDAD LATINA DE PANAMÁ**

**E. S. D.**

**Estimados Señores:**

La (el) suscrita (o) notifica haber revisado por solicitud de la (el) estudiante Juan Carlos Nieto Batista, con cédula de identidad personal número 7-713-968, el proyecto de Investigación Final de Graduación titulado “Desarrollo de un modelo de diagnóstico basado en EfficientNet-B0 para la detección de derrame pleural en radiografías de tórax de pacientes adultos”, y a su vez doy fe de que el documento cumple satisfactoriamente con todos los requisitos formales de ortografía y de redacción exigidos por el idioma español.

Atentamente



2005-001RE

**Firma del Profesor (a) de Español**

**Nombre del o la profesor)a:** Raquel Elida Escala Díaz

**Cédula de identidad:** 8-376-39



**NOTA:** Este es un formato de carta para él o la profesor (a) de español que le revise el proyecto final de graduación

REPÚBLICA DE PANAMÁ  
TRIBUNAL ELECTORAL

**Raquel Elida Escala Diaz**

NOMBRE USUAL:  
FECHA DE NACIMIENTO: 27-MAY-1971  
LUGAR DE NACIMIENTO: PANAMÁ, PANAMÁ  
SEXO: F TIPO DE SANGRE:  
EXPEDIDA: 06-JUN-2019 EXPIRA: 06-JUN-2029

376-39



UNIVERSIDAD DE PANAMA  
LA FACULTAD DE  
*Humanidades*

EN VIRTUD DE LA POTESTAD QUE LE CONFIEREN LA LEY Y EL ESTATUTO UNIVERSITARIO,  
HACE CONSTAR QUE

*Raquel Elida Escala Diaz*

HA TERMINADO LOS ESTUDIOS Y CUMPLIDO CON LOS REQUISITOS  
QUE LE HACEN ACREEDOR AL TITULO DE  
*Licenciada en Humanidades  
con Especialización en Español*

Y EN CONSECUENCIA, SE LE CONCEDE TAL GRADO CON TODOS LOS DERECHOS,  
HONORES Y PRIVILEGIOS RESPECTIVOS, EN TESTIMONIO DE LO CUAL SE LE EXPIDE  
ESTE DIPLOMA EN LA CIUDAD DE PANAMA A LOS *tres*  
DIAS DEL MES DE *Marzo* DE MIL NOVECIENTOS *noventa y siete*

  
Secretaría General  
Diploma 54156  
Identificación Personal 8-376-39

  
Decano

  
Rector





# UNIVERSIDAD DE PANAMA

LA FACULTAD DE

## Ciencias de la Educación

EN VIRTUD DE LA POTESTAD QUE LE CONFIEREN LA LEY Y EL ESTATUTO UNIVERSITARIO,  
HACE CONSTAR QUE

**Raquel Elida Escala Díaz**

HA TERMINADO LOS ESTUDIOS Y CUMPLIDO CON LOS REQUISITOS  
QUE LE HACEN ACREEDOR, CON ALTOS HONORES, AL TITULO DE

**Profesora de Educación Media con  
Especialización en Español**

Y EN CONSECUENCIA SE LE CONCEDE TAL GRADO CON TODOS LOS DERECHOS,  
HONORES Y PRIVILEGIOS RESPECTIVOS, EN TESTIMONIO DE LO CUAL SE LE EXPIDE  
ESTE DIPLOMA EN LA CIUDAD DE PANAMÁ, A LOS *diecinueve*  
DÍAS DEL MES DE *junio* DEL AÑO DOS MIL *siete*.

Diploma 148,376  
Identificación Personal 8-376-39

Secretario General

Decano

Rector