



Universidad Autónoma de Querétaro  
Facultad de Ingeniería  
Maestría en Ciencias en Inteligencia Artificial

Predicción del daño pulmonar ocasionado por Fibrosis  
Pulmonar Idiopática mediante aprendizaje profundo en  
imágenes de Tomografía Computarizada de tórax

Tesis

Que como parte de los requisitos para obtener el Grado de  
Maestro en Ciencias en Inteligencia Artificial

Presenta

Ing. Sheila Leyva López

---

Dirigido por:

Dr. Sebastián Salazar Colores

---

Co-dirigido por:

Dr. Jesús Carlos Pedraza Ortega

---

Dr. Sebastián Salazar Colores  
Presidente

Dr. Jesús Carlos Pedraza Ortega  
Secretario

Dr. Saúl Tovar Arriaga  
Vocal

Dr. Edgar Efrén Lozada Hernández  
Suplente

Dr. Juan Manuel Ramos Arreguín  
Suplente

Centro Universitario, Querétaro, Qro.  
Fecha de aprobación por el Consejo Universitario (mes y año)  
México



Dirección General de Bibliotecas y Servicios Digitales  
de Información



Predicción del daño pulmonar ocasionado por Fibrosis  
Pulmonar Idiopática mediante aprendizaje profundo  
en imágenes de Tomografía Computarizada de tórax

**por**

Sheila Leyva López

se distribuye bajo una [Licencia Creative Commons  
Atribución-NoComercial-SinDerivadas 4.0 Internacional](#).

**Clave RI:** IGMAC-311375



# Dedicatorias

Dedico esta tesis a mi amada abuela, *Margarita*, una mujer de coraje y determinación que, en su época, apenas pudo estudiar hasta primer grado de primaria debido a las limitaciones impuestas a las mujeres. A pesar de las circunstancias de su tiempo, ella se dedicó a aprender de forma autodidacta las habilidades fundamentales de lectura y escritura. Mientras que en aquel entonces se priorizaban las habilidades domésticas tradicionales, hoy en día, en un mundo en constante cambio, he tenido el privilegio de perseguir mi pasión por la tecnología, culminando en la obtención de mi maestría en Ciencias en Inteligencia Artificial.

Mi querida abuela, tu historia de lucha y sacrificio ha sido mi inspiración constante. Si bien no he heredado tus habilidades culinarias, he heredado tu determinación y tu deseo de romper barreras. Esta tesis es un testimonio de tu fuerza y una promesa de que continuaré trabajando incansablemente para cerrar la brecha entre la tecnología y las mujeres, tal como tú cerraste la brecha entre generaciones con tu amor y sabiduría.

Gracias por ser mi fuente de inspiración y por enseñarme que el conocimiento no tiene límites ni género. Siempre llevaré con orgullo tu espíritu valiente en cada paso que dé en el mundo.

Dedico esta tesis a mi increíble madre, *Lizbeth*, una mujer cuyo amor incondicional y apoyo han sido la fuerza motriz detrás de todas mis metas y sueños. A lo largo de mi vida, ella ha sacrificado todo por mi hermana y por mí, demostrando una determinación y dedicación que no tienen límites.

A pesar de nuestras diferencias y desacuerdos, mi madre siempre ha estado a mi lado, respaldándome en cada decisión que he tomado. Sé que, sin importar cuán audaces sean mis

## IV

objetivos, ella siempre responderá con un sincero '¿cómo le hacemos?'.

Mamá, tu compromiso con mi bienestar y tu voluntad de apoyarme en cada paso del camino son un regalo inestimable que nunca dejaré de apreciar. Esta tesis es un modesto reflejo de la educación y los valores que me inculcaste desde el principio.

Dedico este trabajo a mi querida hermana, *Brissa*, quien al ser mi hermana menor me ve como una fuente de inspiración, sin saber que es ella mi motivación. A lo largo de nuestras vidas, hemos enfrentado dificultades juntas, y a pesar de los desafíos, has mantenido un espíritu valiente y una sonrisa en tu rostro.

Quiero que sepas, hermana, que mi deseo más profundo es que siempre seas feliz y que logres todo lo que te propongas. Esta tesis es un testimonio de nuestra determinación compartida y del camino que estamos abriendo para las futuras generaciones de nuestra familia.

Somos la generación que está derribando barreras y persiguiendo nuestros sueños, y quiero que sepas que siempre estaré a tu lado, apoyándote en cada paso del camino. Juntas, somos capaces de lograr cualquier cosa.

# Agradecimientos

Quiero expresar mi sincero agradecimiento a todas las personas e instituciones que contribuyeron a la realización de esta tesis:

A mi asesor, el Dr. Sebastián Salazar, por su orientación experta, paciencia y dedicación. Sus consejos fueron invaluable para dar forma a esta investigación.

A mi co-asesor, el Dr. Carlos Pedraza, por compartirme su sabiduría y experiencia. Su guía fue imprescindible para llevar a cabo esta investigación.

A mi familia, en especial a mi abuela y mi madre, Margarita y Lizbeth, por su apoyo inquebrantable y su fe en mí durante todos estos años, en lo personal y académico. También a mi hermana, Brissa, por su confianza y fortaleza que me ha inspirado a lo largo de mi vida.

A mis amigos y compañeros de clase, quienes compartieron conmigo largas noches de estudio y discusiones académicas que enriquecieron mi comprensión del tema, especialmente a Gerardo Hernández, Enrique Mena, Javier Anguiano, Omar Hernández y Gabriela Flores.

A la Universidad Autónoma de Querétaro por proporcionar los recursos y el ambiente propicios para llevar a cabo esta investigación. Agradezco especialmente a la Biblioteca de la universidad por su amplia colección de literatura académica.

Al Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCYT) por la beca de investigación que financió este proyecto.

Al Centro de Investigaciones en óptica, A.C., por su colaboración en las pruebas de laboratorio y por su apoyo técnico.

Por último, agradezco a todas las personas que participaron de manera directa o indirecta en mi proceso para la realización de esta tesis.

VI

A todos ustedes, mi más profundo agradecimiento. Sin su apoyo y contribuciones, esta tesis no habría sido posible.

# Índice general

<b>1</b>	<b>Introducción</b>	<b>1</b>
<b>2</b>	<b>Fundamentación teórica</b>	<b>3</b>
2.1	Fibrosis Pulmonar Idiopática (FPI)	3
2.2	Tomografía Axial Computarizada (TAC)	4
2.3	Función pulmonar	8
2.4	Redes neuronales artificiales	9
2.5	Redes Neuronales Convolucionales	10
2.6	Aprendizaje Profundo	10
2.6.1	Aprendizaje Supervisado	11
2.6.2	Aprendizaje No Supervisado	12
2.7	Módulos de atención	12
2.7.1	Self-Attention	12
2.7.2	Multi-Head Attention	13
2.7.3	Efficient Channel Attention	13
2.8	Cifras de mérito para evaluación del método de predicción	14
<b>3</b>	<b>Antecedentes</b>	<b>17</b>
<b>4</b>	<b>Hipótesis</b>	<b>23</b>
<b>5</b>	<b>Objetivos</b>	<b>25</b>
5.0.1	Objetivo General	25
5.0.2	Objetivos específicos	25



<b>6 Metodología</b>	<b>27</b>
6.1 Equipo de Cómputo . . . . .	27
6.2 Base de datos . . . . .	27
6.3 Método . . . . .	28
<b>7 Resultados y discusión</b>	<b>33</b>
<b>8 Conclusiones</b>	<b>49</b>
<b>9 Anexo 1. Extenso de resultados experimentales</b>	<b>57</b>
<b>10 Anexo 2. Módulo de segmentación</b>	<b>71</b>
<b>11 Anexo 3. Análisis de la base de datos OSIC</b>	<b>75</b>
11.1 CVF . . . . .	77
11.2 Porcentaje de CVF. . . . .	78
11.3 Edad . . . . .	79
11.4 Sexo . . . . .	80
11.5 Estado del fumador . . . . .	81
<b>12 Anexo 4. Actividades extracurriculares</b>	<b>83</b>

# Lista de Tablas

3.1	Estado del arte. . . . .	20
6.1	Contenido de la base de datos. . . . .	28
7.1	Valores de $LLL_m$ utilizando modelos predicción de la familia de EfficientNet como funciones codificadoras en cada uno de los experimentos. . . . .	40
7.2	Valores de $LLL_m$ utilizando modelos predicción de la familia de ResNet y ResNext como funciones codificadoras en cada uno de los experimentos. . . .	41
7.3	Valores de $LLL_m$ utilizando la arquitectura de la Figura 7.5 y los experimentos del punto 8. . . . .	44
9.1	Experimentos y métrica RMSE con su respectiva desviación estándar obtenidas.Parte 1. . . . .	58
9.3	Experimentos y métrica RMSE con su respectiva desviación estándar obtenidas.Parte 2. . . . .	62
9.5	Experimentos y métrica $LLL_m$ con su respectiva desviación estándar obtenidas.Parte 1. . . . .	66
10.1	Comparison of the metrics reported by the authors of Fibro-CoSANet, those obtained after reproducing the same experiment, and after modifying the input to the network with a guided image. . . . .	74

# Índice de figuras

2.1	Fibrosis pulmonar. Imagen adaptada de [1]. . . . .	4
2.2	Tomografía de tórax: corte a) axial, b) coronal y c) sagital [2]. . . . .	5
2.3	Lóbulos inferiores en paciente con FPI [2]. . . . .	6
2.4	Lóbulos inferiores. Muestra elementos quísticos pulmonares bilaterales [2]. . .	7
2.5	Patrón reticular causado por el engrosamiento intersticial intralobular [2]. . .	7
2.6	Gráfica de estudio de espirometría. Imagen adaptada de [3]. . . . .	8
2.7	Arquitectura general de una red neuronal artificial. Donde n, m y k son enteros.	9
2.8	Red neuronal convolucional. Imagen adaptada de [4]. . . . .	10
2.9	Estratificación de áreas de la IA. . . . .	11
6.1	Diagrama de actividades del proyecto. . . . .	29
7.1	Arquitectura el modelo de predicción. . . . .	34
7.2	Arquitectura el modelo de predicción. . . . .	36
7.3	Módulo de segmentación. . . . .	37
7.4	Arquitectura de la red con 10 imágenes a las entrada. . . . .	38
7.5	Arquitectura de modelo de predicción propuesto. . . . .	42
7.6	Función de pérdida durante el entrenamiento del modelo. . . . .	45
7.7	Función de pérdida durante la etapa de validación del modelo. . . . .	46
7.8	Valor de RMSE durante el entrenamiento del modelo. . . . .	47
7.9	Valor de $LLL_m$ durante el entrenamiento del modelo. . . . .	48
11.1	Matriz de correlación de Pearson. . . . .	76
11.2	Histograma del parámetro CVF. . . . .	78

11.3 Gráfico circular del parámetro porcentaje . . . . .	78
11.4 Histograma de la variables Edad. . . . .	80
11.5 Gráfico circular de la variables sexo. . . . .	80
11.6 Relación entre la variable Edad y CVF. . . . .	81
11.7 Gráfica circular del estado del fumador. . . . .	82
12.1 Votos aprobatorios: director de tesis. . . . .	84
12.2 Votos aprobatorios: co-director de tesis. . . . .	85
12.3 Votos aprobatorios: secretario. . . . .	86
12.4 Aprobación por comité de ética. . . . .	87
12.5 Registro de protocolo. . . . .	88
12.6 Constancia de manejo de la lengua inglés. . . . .	89
12.7 Constancia de comprensión de textos en inglés. . . . .	90
12.8 Artículo publicado en el congreso MECAMEX como primer autor. . . . .	91
12.9 Artículo publicado en el congreso MECAMEX como tercer autor. . . . .	92
12.10Aportación social: plantilla en formato látex para protocolo de tesis. . . . .	92
12.11Actividad extracurricular: Cloud Skills Challenge de Microsoft. . . . .	93
12.12Reconocimiento por participación en el XX encuentro Participación de la Mujer en la Ciencia en Centro de Investigaciones en Óptica (CIO). . . . .	94
12.13Plataforma web desarrollada presentada en el XX encuentro Participación de la Mujer en la Ciencia en el CIO. . . . .	95
12.14Trabajo en extenso entregado en el XX encuentro Participación de la Mujer en la Ciencia en el CIO. . . . .	96
12.15Artículo presentado en el 2023 IEE Conference on Artificial Intelligence (CAI) en Santa Clara, California, USA. En Junio 5 y 6 del año 2023. . . . .	97
12.16Artículo presentado en CAI, ahora en la plataforma IEEE Xplore. . . . .	98
12.17Asistencia al AI CODE FEST TECH N' FEST llevado a cabo por Globant, en la ciudad de Guadalajara, México, el 10 de junio del 2023. . . . .	99
12.18Incorporación a la comunidad de Microsoft Learn Student Ambassadors. . . . .	100

12.19Curso oficial: AZ-900T00-A-Microsoft Azure Fundamentals. . . . . 101

# Resumen

La fibrosis pulmonar idiopática (FPI) es una enfermedad crónica, progresiva y limitante. Consiste en una mala cicatrización del tejido pulmonar luego de que este sufre algún tipo de daño. De los 200 tipos de fibrosis pulmonar existentes la FPI es la más común y recibe este nombre porque las causas de la aparición del padecimiento se desconocen.

En el presente proyecto de tesis de posgrado se propone el desarrollo de un método basado en técnicas de aprendizaje profundo: redes neuronales convolucionales en 3D, con el propósito de predecir el daño pulmonar como consecuencia de la fibrosis idiopática en pulmones. Dicho método consiste en la predicción de los valores de capacidad vital forzada siguientes a partir de una primera imagen de tomografía axial computarizada de tórax, un valor inicial de capacidad vital forzada e información adicional como edad, sexo y el estado del fumador, es decir, si durante el estudio el paciente era un fumador activo, ex fumador o nunca había fumado.

**Palabras clave:** Red Neuronal Convolucional, Tomografía Axial Computarizada, Fibrosis Pulmonar Idiopática, Capacidad Vital Forzada, Multi-Head Attention.



# Abstract

Idiopathic pulmonary fibrosis (IPF) is a chronic, progressive and limiting disease. It consists of poor healing of lung tissue after it is damaged in some way. Of the 200 types of pulmonary fibrosis, IPF is the most common and is so named because the causes of the onset of the condition are unknown.

This graduate thesis project proposes the development of a method based on deep learning techniques with the purpose of predicting lung damage as a consequence of idiopathic fibrosis in the lungs. This method consists of the prediction of the following forced vital capacity values from a first computed axial tomography image of the thorax, an initial forced vital capacity value and additional information such as age, sex and smoking status, that is, if during the study the patient was an active smoker, ex-smoker or had never smoked.

**Keywords.** Convolutional Neural Network, Computed Axial Tomography, Idiopathic Pulmonary Fibrosis, Forced Vital Capacity, Multi-Head Attention.





# Capítulo 1

## Introducción

La fibrosis pulmonar idiopática (FPI) es una enfermedad crónica, progresiva y debilitante que se caracteriza principalmente por una tos persistente que evoluciona a lo largo de varios meses, a menudo precedida de una enfermedad respiratoria aguda [5]. Hasta la fecha, la FPI sigue siendo una enfermedad incurable. Sin embargo, un diagnóstico preciso y oportuno puede contribuir significativamente a reducir la mortalidad asociada a esta patología y a mejorar la esperanza y la calidad de vida de los pacientes afectados. Cabe destacar que, tras la aparición de los primeros síntomas, el intervalo medio de supervivencia oscila entre 2 y 5 años [5][6].

El objetivo principal de este trabajo es mejorar la predicción del daño pulmonar causado por la FPI mediante la implementación de redes neuronales convolucionales (CNN, por sus siglas en inglés) y módulos de atención. En este sentido, este trabajo presenta un enfoque integral basado en el aprendizaje multimodal que predice la disminución de la capacidad vital forzada (CVF) en pacientes con FPI, utilizando una base de datos híbrida, es decir, que incluye imágenes de Tomografía Computarizada (TC) e información demográfica en marcos de CNNs con una capa de atención apilada.



# Capítulo 2

## Fundamentación teórica

A lo largo de este proyecto se utilizarán conceptos del área de la inteligencia artificial y del campo de la medicina, por lo cual es necesario definirlos para entrar en contexto.

### 2.1. Fibrosis Pulmonar Idiopática (FPI)

La fibrosis pulmonar idiopática (FPI) es una enfermedad crónica, progresiva y limitante que principalmente se caracteriza por una tos persistente que evoluciona a lo largo de meses, y en la mayoría de los casos le precede un cuadro respiratorio agudo [7]. Esta se genera cuando el tejido pulmonar sufre daños y entonces el tejido sano se reemplaza por una matriz extracelular alterada, es decir, se producen cicatrices (ver Figura 1), lo que eventualmente conlleva a una disminución de la distensibilidad pulmonar (capacidad de modificar su volumen en las tres dimensiones) [8], un intercambio de gases interrumpido y en última instancia insuficiencia respiratoria e incluso la muerte [9], [1], [10].




Figura 2.1: Fibrosis pulmonar. Imagen adaptada de [1].

En la Figura 2.1, del lado izquierdo se puede observar la anatomía de los alvéolos de un sistema respiratorio sano, mientras que del lado derecho se observa cómo la cicatrización, debido a la fibrosis, reduce los espacios de aire de los alvéolos.

## 2.2. Tomografía Axial Computarizada (TAC)

Por otro lado, la tomografía computarizada (TC) o también llamada tomografía axial computarizada (TAC) es un estudio utilizado para apoyar el diagnóstico médico. Consiste en una secuencia de imágenes de Rayos X en cortes axiales, sagitales y coronales (ver Figura 2.2), que posteriormente se convierten en imágenes tridimensionales de órganos internos, huesos, tejidos blandos e incluso vasos sanguíneos [11], [12].

Específicamente una TAC de tórax se indica cuando se requiere demostrar la presencia de alguna enfermedad pulmonar de la que se tiene sospecha clínica, pero la radiografía es normal; o se busca caracterizar con mayor precisión una enfermedad pulmonar que ya fue detectada inicialmente con rayos X, y así identificar el patrón morfológico de la patología; también cuando se requiere evaluar la actividad del padecimiento y sus posibles tratamientos; así como para indicar el lugar adecuado para tomar una biopsia para su posterior análisis.




Figura 2.2: Tomografía de tórax: corte a) axial, b) coronal y c) sagital [2].

En la Figura 2.2, se muestran los tres distintos tipos de cortes de una TAC de tórax. Los cortes axiales o helicoidales son aquellos que se realizan en dirección de pies a cabeza; los cortes coronales van desde la parte posterior del cuerpo hasta el frente del mismo; y los cortes sagitales son imágenes que se toman desde el extremo derecho al extremo izquierdo del paciente.

Dentro de los patrones más comunes en las imágenes de TAC de pacientes con FPI se encuentran [2]:

1. *Panalización*: este tipo de patrón recibe este nombre por su similitud con la estructura de un panal de abejas (ver Figura 3), debido a la cicatrización que sufre el tejido pulmonar.




Figura 2.3: Lóbulos inferiores en paciente con FPI [2].

En la Figura 2.3 se pueden observar flechas negras que señalan la panalización y se pueden observar opacidades reticulares periféricas:

- Disminución global del volumen pulmonar.
- Opacidades pulmonares: tanto reticular como de localización basal y periférica (ver Figura 2.4).
- Patrón quístico. Se pueden observar elementos redondeados de paredes finas (1 a 3 mm de grosor), definidas y con aire dentro de ellos (ver Figura 2.4).




Figura 2.4: Lóbulos inferiores. Muestra elementos quísticos pulmonares bilaterales [2].

2. Engrosamiento intersticial intralobular. Fina trama reticular presente desde las estructuras peribroncovasculares del centro del lobulillo hasta los septos interlobulares, morfológicamente similar a una "telaraña" (ver Figura 2.5).




Figura 2.5: Patrón reticular causado por el engrosamiento intersiticial intralobular [2].



### 2.3. Función pulmonar

Asimismo, la prueba de función pulmonar (PFP) es una evaluación para conocer el funcionamiento de los pulmones, es decir, conocer si se inhala y exhala el aire de los pulmones adecuadamente [13]. Dicha evaluación puede incluir espirometrías, pruebas de volumen pulmonar, oximetría, pruebas de fracción de óxido nítrico espirado y/o pruebas de gases en sangre arterial no invasiva [14], [15]. Una de las pruebas de función pulmonar más reconocida y estandarizada es la espirometría. La cual es del tipo no invasiva que mide flujos y volúmenes de aire exhalado e inspirado y ayuda a identificar si existen obstrucciones al flujo respiratorio. Dentro de esta prueba se manejan dos principales parámetros fisiológicos: volumen espiratorio forzado en el primer segundo ( $FEV_1$ ) y capacidad vital forzada ( $CVF$ ) (ver Figura 2.6), esta última se refiere al volumen máximo de aire exhalado de manera forzada por la boca después una inspiración máxima [16].

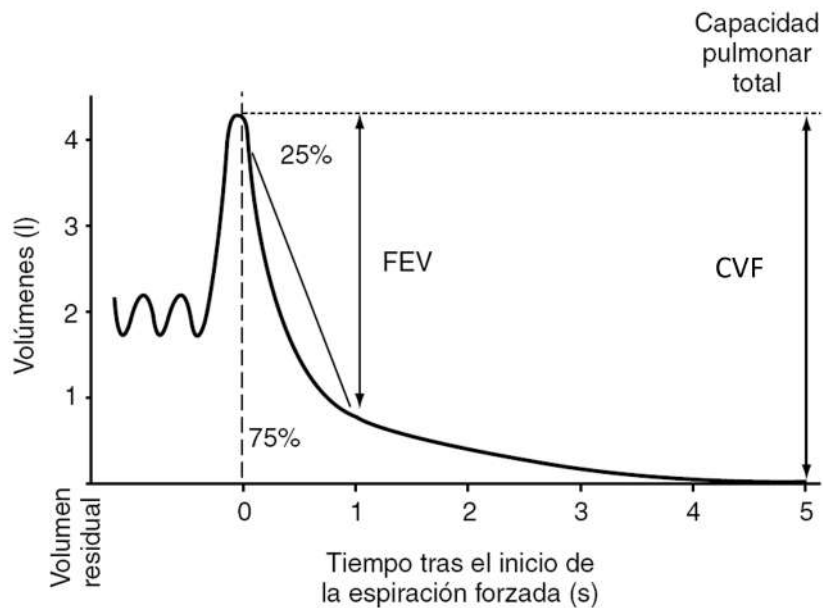


Figura 2.6: Gráfica de estudio de espirometría. Imagen adaptada de [3].

Se considera que un valor de  $CVF$  es normal cuando es mayor del 80 % de su valor teórico [17] y su suele disminuir en pacientes con FPI.

## 2.4. Redes neuronales artificiales

Por otro lado, en el área de la IA, las Redes Neuronales Artificiales (RNA), son redes que tratan de imitar la estructura neuronal del cerebro humano. Al igual que en el contexto biológico, la neurona artificial es la unidad elemental de una RNA, cuando se unen más de una neurona se forman capas, y varias capas a su vez forman una red o redes neuronales, para finalmente obtener un sistema que tiene datos de entrada y salida [18] (ver Figura 2.7).

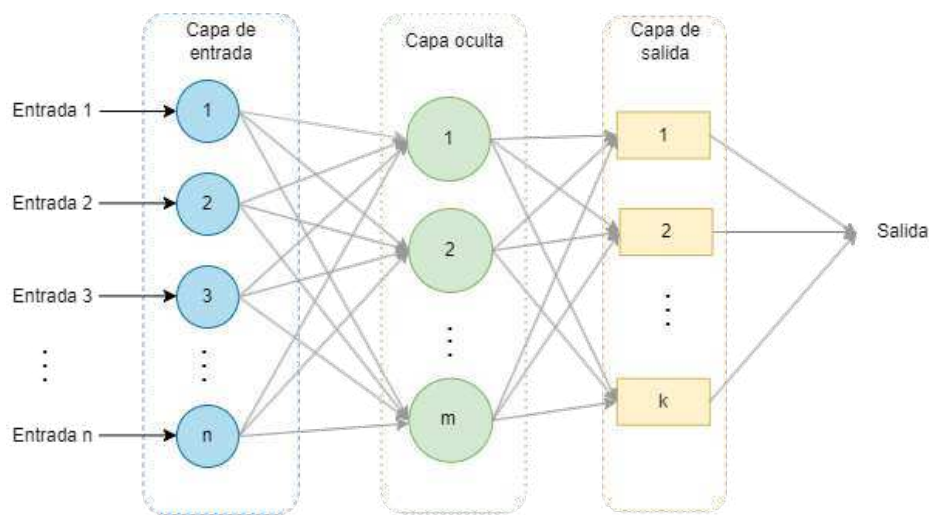


Figura 2.7: Arquitectura general de una red neuronal artificial. Donde  $n$ ,  $m$  y  $k$  son enteros.

Normalmente, como se observa en la Figura 2.7, su estructura se compone en tres secciones, la primera es la capa de entrada, en donde se reciben los datos (que pueden ser de uno hasta  $n$  cantidad de datos), la segunda sección consta de una o hasta  $m$  capas ocultas, aquí es donde se procesan y analizan los datos, y por último están las capas de salida (desde una hasta  $k$  capas), estas arrojan decisiones y/o conclusiones de los datos recibidos.

Existen distintas estructuras de redes neuronales artificiales, y los sistemas pueden ser tan complejos como se requieran, a continuación se describe el concepto de redes neuronales convolucionales, dado que es la arquitectura de aprendizaje profundo más popular en imágenes médicas.

## 2.5. Redes Neuronales Convolucionales

Las redes neuronales convolucionales (CNN, por sus siglas en inglés) se utilizan ampliamente para la clasificación de imágenes y visión por computadora, dado que, resultan ser bastante eficientes en la obtención de patrones en imágenes, como lo son, líneas, gradientes, círculos o incluso ojos y/o caras [19]. Generalmente son redes neuronales de más de 20 o 30 capas [19], ver Figura 2.8.

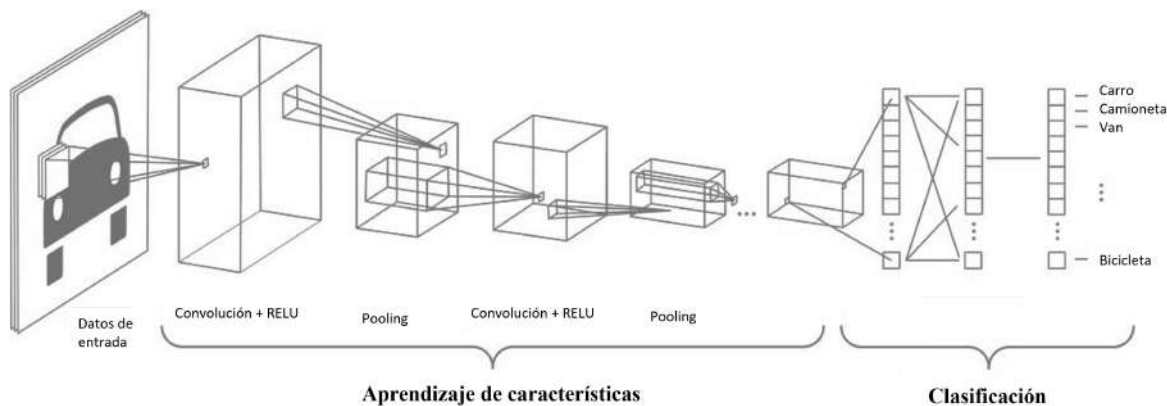


Figura 2.8: Red neuronal convolucional. Imagen adaptada de [4].

En la Figura 2.8 se muestra el diagrama general de una red neuronal convolucional, la cual reconoce ciertas características y patrones específicos en un conjunto de imágenes. Durante la etapa de aprendizaje de características se introducen los datos de entrada (imágenes) a filtros convolucionales para la activación de características específicas, solo estas características pasaran a la capa siguiente, en la etapa de *pooling* o agrupamiento se reduce la cantidad de variables que la red debe aprender, para finalmente pasar a la clasificación [4].

## 2.6. Aprendizaje Profundo

Ahora bien, el aprendizaje profundo (DL, por sus siglas en inglés) es una técnica del aprendizaje automático (Ver Figura 2.9) que consiste en la imitación de la estructura y función del cerebro humano a través de 3 o más capas llamadas redes neuronales artificiales [20],

[21]. Su principal característica es la enorme cantidad de capas ocultas que la componen.

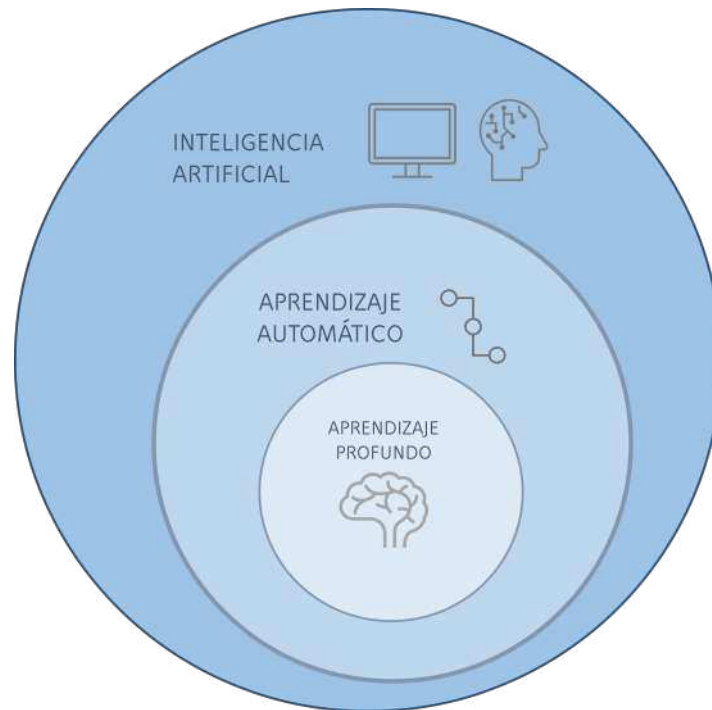


Figura 2.9: Estratificación de áreas de la IA.

Cabe mencionar que los algoritmos basados en aprendizaje profundo presentan un mejor desempeño a medida que se aumenta la cantidad de datos que utilizan, lo que hace que el aprendizaje profundo destaque por su capacidad para procesar grandes cantidades de datos [20].

A partir del volumen, tipo de datos y la finalidad del algoritmo, se escoge la técnica de aprendizaje más adecuada, ya sea aprendizaje supervisado, no supervisado o por refuerzo.

### 2.6.1. Aprendizaje Supervisado

Este tipo de aprendizaje consiste en proporcionarle a la red neuronal un conjunto de datos debidamente etiquetado y sea la misma red quien se encargue de encontrar patrones dentro de los datos para posteriormente analizarlos. El algoritmo es entrenado con ejemplos preclasificados para posteriormente evaluar su desempeño con datos de prueba [22].

### 2.6.2. Aprendizaje No Supervisado

El aprendizaje no supervisado es una rama del aprendizaje automático (machine learning) que se enfoca en descubrir patrones, estructuras y relaciones ocultas en conjuntos de datos sin etiquetar ni categorías predefinidas. A diferencia del aprendizaje supervisado, en el cual se proporciona un conjunto de datos de entrenamiento etiquetado para que el algoritmo aprenda a asignar correctamente nuevas instancias, el aprendizaje no supervisado opera con datos no etiquetados.

## 2.7. Módulos de atención

En esta sección, se explorarán tres módulos fundamentales utilizados en el campo del aprendizaje automático para mejorar la capacidad de los modelos y capturar características importantes en los datos. Estos módulos son: el módulo de auto-atención (Self-Attention), la atención multi-cabeza (Multi-Head Attention) y la atención eficiente de canales (Efficient Channel Attention). Cada uno de ellos desempeña un papel crucial en la mejora del rendimiento y la eficiencia de los modelos de aprendizaje automático. A continuación, se analizará en detalle cada uno de estos módulos, su funcionamiento y su relevancia en diferentes tareas de aprendizaje automático.

### 2.7.1. Self-Attention

El módulo de Autoatención, o Self-Attention en inglés, es una componente clave en las redes neuronales transformer. También conocido como "Scaled Dot-Product Attention", este módulo permite que un modelo aprenda las relaciones entre diferentes elementos de una secuencia al asignar pesos a esos elementos en función de su importancia relativa. El módulo de Self-Attention utiliza consultas, claves y valores para calcular una atención ponderada sobre los elementos de entrada. Calcula la similitud entre las consultas y las claves, y luego utiliza esos valores de similitud para ponderar los valores y producir una salida atendida. Esto permite que el modelo se centre en diferentes partes de la secuencia según la importancia

relativa de cada elemento [23].

### **2.7.2. Multi-Head Attention**

La atención multi-head, o Multi-Head Attention en inglés, es una extensión del módulo de Self-Attention. En lugar de utilizar un solo conjunto de consultas, claves y valores, se utilizan múltiples conjuntos en paralelo. Cada conjunto, conocido como: cabeza, aprende a enfocarse en diferentes aspectos o relaciones dentro de los datos. Cada cabeza de atención calcula una atención ponderada independiente, y las salidas de todas las cabezas se concatenan y se proyectan en un espacio dimensional final. Esto permite que el modelo capture diferentes tipos de información y relaciones en paralelo, mejorando su capacidad para capturar características y patrones complejos [23].

### **2.7.3. Efficient Channel Attention**

La atención eficiente de canales, o Efficient Channel Attention en inglés, es una técnica que se utiliza para mejorar la eficiencia y la capacidad de enfoque de los modelos de aprendizaje automático en los canales o características de los datos. En lugar de aplicar atención a todos los canales por igual, la atención eficiente de canales busca identificar y enfocarse en los canales más relevantes o informativos. Esto se logra mediante el cálculo de pesos o importancias para cada canal, que indican su relevancia en la tarea en cuestión. Al asignar mayores pesos a los canales más importantes y menores pesos a los menos relevantes, se logra una atención más selectiva [24].

La atención eficiente de canales permite que los modelos se centren en las características más importantes, lo que puede mejorar la capacidad de generalización y la eficiencia computacional al reducir la cantidad de cálculos necesarios en los canales menos relevantes. Esta técnica es especialmente útil cuando se trabaja con datos de alta dimensionalidad [24].

## 2.8. Cifras de mérito para evaluación del método de predicción

Para evaluar los modelos, se consideran dos métricas principales: la probabilidad logarítmica de Laplace ( $LLL_m$ ) (ecuación 2.1), que mide la capacidad de un modelo para predecir correctamente las clases o los valores de un conjunto de datos de prueba, utilizando la probabilidad logarítmica como medida del error. Una de las ventajas de esta métrica es que evita los problemas de sobreajuste y subestimación de la precisión del modelo. Además, es especialmente útil cuando se trabaja con conjuntos de datos pequeños o desequilibrados [25]. También se utiliza el error cuadrático medio ( $RMSE$ ) (ecuación 2.2), que evalúa la precisión de un modelo de regresión. El  $RMSE$  mide la diferencia cuadrática media entre los valores reales y los valores predichos por el modelo [26].

$$LLL_m = \log\left(P + \frac{1}{N + K}\right) \quad (2.1)$$

donde:

- $LLL_m$  representa a Laplace Log-Likelihood o verosimilitud del logaritmo de Laplace en español.
- $P$  representa el número de predicciones correctas realizadas por el modelo en el conjunto de datos de prueba.
- $N$  es el tamaño del conjunto de datos de prueba.
- $K$  es el número de clases o valores posibles.

$$RMSE = \sqrt{\frac{\sum(y - y_{pred})^2}{n}} \quad (2.2)$$

donde:

- $n$  representa el número de observaciones en el conjunto de datos.
- $y$  es el valor verdadero de la variable de respuesta.

## 2.8. CIFRAS DE MÉRITO PARA EVALUACIÓN DEL MÉTODO DE PREDICCIÓN 15

- $y_{pred}$  es el valor predicho de la variable de respuesta.





# Capítulo 3

## Antecedentes

El campo de la inteligencia artificial (IA) se encuentra en constante crecimiento. Hoy en día existe una inmensa cantidad de aplicaciones en nuestra vida diaria, tales como, el procesamiento del lenguaje natural (NLP, por sus siglas en inglés) para el reconocimiento de voz, servicio al cliente a través de chatbots, motores de recomendación, comercio de acciones automatizado, videojuegos, robótica y en el área de la salud [21][27].

En medicina, el uso de imágenes para el diagnóstico es un área de oportunidad para la IA, específicamente para el aprendizaje automático, una subárea de la IA que ha destacado en el campo de imágenes médicas debido a su uso, tanto en el diagnóstico asistido por computadora (CAD, por sus siglas en inglés), como en la radiómica ( que consiste en la obtención de información que no es evidente a la vista humana a partir del uso de técnicas cuantitativas avanzadas de análisis de imagen) [28], y en el análisis de imágenes médicas [29].

Ahora bien, dentro del aprendizaje automático se encuentra un campo denominado: aprendizaje profundo, el cual surgió en el campo de visión por computadora y rápidamente se posicionó en muchos más campos, en los cuales adquirió potencialidad como herramienta auxiliar en la detección de lesiones en imágenes, apoyo en diagnósticos diferenciales y en la estructuración de informes preliminares [27]. Su aparición se dio a finales del año 2012 durante ImageNet Classification, la competencia de visión por computadora más reconocida a nivel mundial, donde un proyecto de aprendizaje profundo utilizó una CNN y obtuvo el

primer lugar [29]. Cabe mencionar que el aprendizaje automático basado en imágenes data de muchos años antes que la fecha mencionada, pero su popularidad se debe a la introducción del nuevo término: aprendizaje profundo [29].

Una vez mencionado todo lo anterior, cabe destacar que una de las herramientas para el diagnóstico de la fibrosis pulmonar idiopática es la visualización de imágenes de tomografía computarizada de tórax en conjunto con pruebas de función pulmonar y/o muestras de tejidos (biopsia) [30]. Es en esta situación donde resulta útil el uso del aprendizaje profundo para detectar, segmentar, clasificar o predecir la enfermedad pulmonar fibrótica. A continuación, se menciona una serie de trabajos relacionados con la predicción de de la fibrosis pulmonar idiopática utilizando técnicas de IA:

- **2020.** En [31] utilizaron el conjunto de datos de Kaggle de OSIC (Open Source Imaging Consortium) [32] para el entrenamiento y las pruebas. Este conjunto de datos incluye información de 176 pacientes únicos, incluyendo TC scans y otros datos clínicos. Compararon varios modelos de aprendizaje automático para predecir la progresión de la FPI. Los modelos incluyen la Regresión Cuantil Múltiple, la Regresión Ridge y la Regresión Elastic Net. Evaluaron la confianza de los modelos utilizando la puntuación OOF (out-of-fold).
- **2021.** En [33] presentan Fibro-CoSAnet, una nueva red de aprendizaje multimodal de extremo a extremo para predecir la disminución de la Capacidad Vital Forzada (FVC) en pacientes con Fibrosis Pulmonar Idiopática (IPF). Fibro-CoSAnet utiliza imágenes de TC e información demográfica en marcos de redes neuronales convolucionales con una capa de atención apilada. Los experimentos extensos en el conjunto de datos de progresión de la fibrosis pulmonar OSIC [32] demostraron la superioridad de Fibro-CoSAnet al lograr una nueva puntuación de registro de Laplace modificado de -6.68.
- **2022.** En [34] muestran una red llamada: Fibrosis-Net. Una red neuronal convolucional profunda diseñada específicamente para predecir la progresión de la fibrosis pulmonar basándose en imágenes de TC, mediciones iniciales de espirometría y metadatos clínicos.

- **2022.** En [35] proponen una arquitectura de aprendizaje profundo llamada FVC-Net para predecir la progresión de la fibrosis pulmonar a partir de la TC del paciente y los metadatos del paciente. La entrada al modelo combina la puntuación de la imagen generada en función del grado de panalización para un paciente identificado en función de las imágenes de pulmón segmentadas y los metadatos. Esta entrada se alimenta luego en una red de 3 capas para obtener la salida final. El modelo mostró una mejora significativa en el rendimiento sobre otros modelos para la log-verosimilitud de Laplace modificada. Se utilizó un conjunto de datos de OSIC para entrenar el modelo, que contiene metadatos CSV junto con las TC para cada paciente. La entrada al modelo pasa por Conv. (convolución), BN (normalización por lotes) y ReLU (unidad lineal rectificadora) dos veces, seguido de averagePooling2D para obtener una única rama concatenada de tamaño 256 por 256 por 64.
- **2023.** En el trabajo [36] presentan un modelo de aprendizaje automático basado en regresión para predecir la disminución de la función pulmonar. Este modelo se desarrolló a través de la optimización de parámetros en una función sigmoidea para predecir la Capacidad Vital Forzada (FVC) futura basada en datos históricos de pacientes. El modelo se entrenó con datos de 172 pacientes de la fuente OSIC y logró una puntuación de Laplace Log Likelihood de -6.8590 en el conjunto de datos privado.
- **2023.** En el artículo [37] proponen un modelo combinado de Red Neuronal Convolutiva - Memoria a Largo Plazo (CNN-LSTM) y Memoria a Largo Plazo - Red Neuronal de Regresión Cuantil (LSTM-QRNN) para manejar la crisis de disminución de la función pulmonar basada en tomografías computarizadas y datos clínicos. El modelo híbrido CNN-LSTM se utiliza para la integración de múltiples cortes de tomografía computarizada 2D y metadatos clínicos para predecir la disminución de la fibrosis pulmonar. Se utiliza el modelo pre-entrenado como EfficientNet y se ajusta el modelo híbrido CNN-LSTM en el conjunto de datos OSIC.

En la siguiente Tabla 3.1 se muestra de manera sintetizada las características más importantes de los trabajos relacionados, mencionados anteriormente.

Tabla 3.1: Estado del arte.

Año	Artículo	RNA	Arquitectura	LLM
2020	Prediction Analysis of Idiopathic Pulmonary Fibrosis Progression	CONV2D	Quantile	-6.92
			Ridge	-6.81
			Elastic Net	-6.72
2021	FIBRO-COSANET: Pulmonary Fibrosis Prognosis Prediction using a convolutional Self-Attention Network & OSIC Pulmonary Fibrosis Progression	CONV2D	EfficientNet-B0	-6.70
			EfficientNet-B1	-6.68
			EfficientNet-B2	-6.68
			EfficientNet-B3	-6.72
			EfficientNet-B4	-6.73
			ResNet-18	-6.73
			ResNet-34	-6.73
			ResNet-50	-6.70
			ResNet-101	-6.71
			ResNet-152	-6.70
ResNeXt-50	-6.70			
ResNeXt-101	6.72			
2022	Fibrosis-Net: A Tailored Deep Convolutional Neural Network Design for Prediction of Pulmonary Fibrosis Progression from Chest CT Images	CONV2D	Elastic Net	-6.82
2022	FVC-NET: An Automated Diagnosis of Pulmonary Fibrosis Progression Prediction Using Honeycombing and Deep Learning	CONV2D	FVC-Net	-6.64

2022	A combined CNN-LSTM and LSTM-QRNN model for prediction of Idiopathic Pulmonary Fibrosis Progression using CT Scans and Clinical Data	CONV2D	su mejor modelo	-6.80
2023	<b>Los modelos de este proyecto con mejor desempeño</b>	<b>CONV3D</b>	<b>fc: ImageNet + 3DCNN + Data Augmentation</b>	<b>-6.68</b>
			<b>fc: ImageNet + 3DCNN + Data Augmentation + L2</b>	<b>-6.69</b>
			<b>fc: ImageNet + 3DCNN + mha_32</b>	<b>-6.70</b>
			<b>fc: ImageNet + 3DCNN</b>	<b>-6.70</b>

Cabe mencionar que la magnitud de trabajos basados en aprendizaje profundo aplicado en tomografías computarizadas de tórax es menor comparado con los trabajos que utilizan imágenes de Rayos X como entrada. Por otro lado, el número de trabajos que combinan los tipos de datos: parámetros clínicos y tomografías computarizadas, es aún más reducido.

Además, es destacable el hecho de que este trabajo es el único que utiliza RNAs del tipo redes neuronales convolucionales en tres dimensiones (3D), dado que, los trabajos anteriores únicamente han realizado las predicciones con redes convolucionales en dos dimensiones (2D).



# Capítulo 4

## Hipótesis

La aplicación de técnicas de aprendizaje profundo mediante redes neuronales convolucionales en imágenes de TAC de tórax y en datos de función pulmonar, así como la edad, sexo y si el paciente es fumador o no, permitirá conocer la evolución del daño pulmonar ocasionado por la FPI en las personas que la padecen.





# Capítulo 5

## Objetivos

### 5.0.1. Objetivo General

Clasificar imágenes de tomografía computarizada de tórax, así como datos de la función pulmonar del paciente para pronosticar la evolución de la fibrosis pulmonar mediante algoritmos de aprendizaje profundo.

### 5.0.2. Objetivos específicos

A continuación, se describen los objetivos específicos necesarios para alcanzar el objetivo general de este proyecto:

- Determinar los principales patrones observados en imágenes de TAC de tórax de pacientes con fibrosis pulmonar idiopática.
- Identificar los principales algoritmos utilizados para predicción en el campo de la imagenología médica.
- Reconocer los principales parámetros de medición de la función pulmonar.
- Predecir las siguientes tres CVFs del paciente a partir de una imagen de TC de tórax y un valor inicial de CVF, así como el sexo, fumador o no fumador y edad.
- Validar predicciones del método de predicción diseñados de forma cuantitativa.



# Capítulo 6

## Metodología

### 6.1. Equipo de Cómputo

Para fines de esta investigación se utilizaron dos equipos de cómputo con características específicas que permitieran llevar a cabo la experimentación de dicho proyecto:

- Equipo 1: AMD Ryzen 5 5600x; RAM 32GB; Windows 11 Pro; NVIDIA RTX 3090 VRAM 24GB.
- Equipo 2: AMD Ryzen 5 5600g; RAM 64 GB; Ubuntu 20.04.6; NVIDIA RTX A6000.

### 6.2. Base de datos

La base de datos proporcionada en [32] consta de 176 sujetos de entrenamiento y 5 sujetos de prueba. Sin embargo, para este estudio, hemos decidido utilizar únicamente el conjunto de entrenamiento. La segmentación de este conjunto de entrenamiento se describe en la sección de metodología. El objetivo principal es predecir las tres últimas mediciones de la CVF, así como un valor de confianza en la predicción. Los datos contenidos en la base de datos consisten en una tomografía computarizada de tórax tomada en la semana cero de seguimiento y parámetros clínicos, que se recogieron en sesiones de seguimiento a lo largo de uno o dos años, según el caso.

Los parámetros clínicos que componen la base de datos se resumen en Tabla 6.1 e incluyen: un identificador único del paciente, el número relativo de semanas anteriores o posteriores a la TC de referencia, la capacidad pulmonar registrada en ml, un campo calculado que aproxima la CVF del paciente como porcentaje de la CVF típica de una persona con características similares, edad, sexo y hábito con el tabaco.

Tabla 6.1: Contenido de la base de datos.

Datos	
TC de tórax	Una TC de tórax inicial por cada paciente.
Semanas	Número relativo de semanas previas/posteriores a la TC inicial (puede ser negativa).
FVC	Capacidad pulmonar registrada en ml.
Porcentaje	FVC del paciente como un porcentaje de la FVC típica para una persona de características similares.
Edad	Años
Sexo	Mujer/Hombre
Estado del fumador	Actualmente fumador, exfumador o nunca ha fumado.

### 6.3. Método

En el siguiente diagrama de bloques (Figura 6.1) se proponen las etapas de la metodología para lograr la predicción de la evolución de fibrosis pulmonar. Este proyecto se plantea con una duración de dos años, asesorado por un director y un codirector.

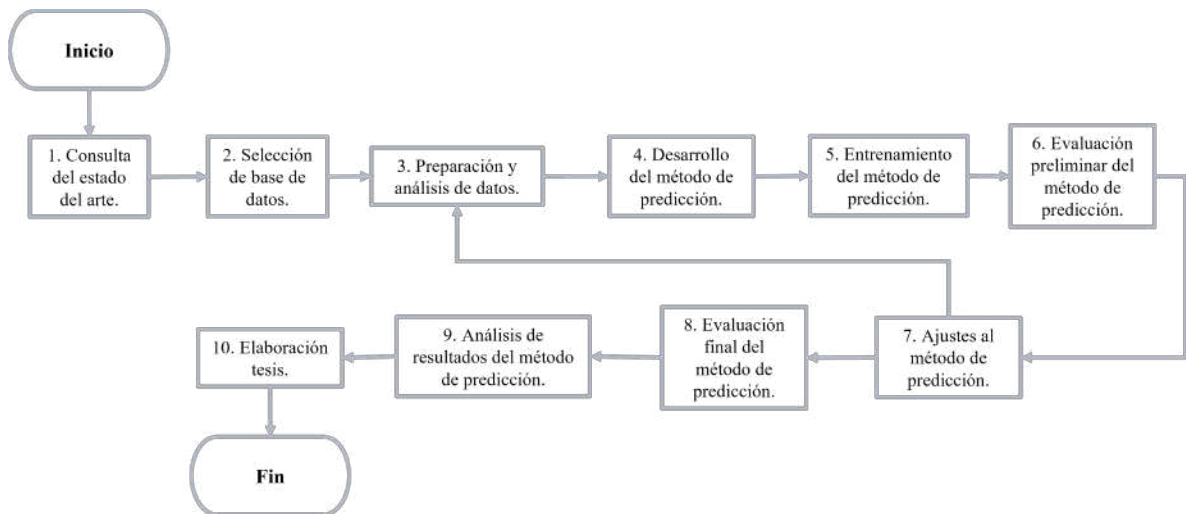


Figura 6.1: Diagrama de actividades del proyecto.

A continuación se describen cada uno de los pasos implicados en las etapas mostradas en el diagrama anterior.

1. **Consulta del estado del arte.** Investigación de los trabajos relacionados con este proyecto, así como de los conceptos básicos y claves para este proyecto, tales como:
  - a) Fibrosis Pulmonar Idiopática.
  - b) Tomografía Computarizada.
  - c) Función pulmonar.
  - d) Aprendizaje Profundo.
  - e) Redes Neuronales Artificiales.
  - f) Aprendizaje Supervisado.
  - g) Aprendizaje No Supervisado.
  - h) Módulos de Atención.
    - 1) Self-Attention
    - 2) Multi-Head Attention
    - 3) Efficient Channel Attention

- i)* Cifras de mérito para evaluación del método de predicción.
- 2. **Selección de base de datos a utilizar.** La base de datos debe contener imágenes de TC de tórax y valores de la CVF medida en distintas ocasiones en pacientes con FPI.
- 3. **Preparación y análisis de datos.** Preprocesar las imágenes de TC en caso de que estas lo requieran, para posteriormente trabajar con ellas. Así como dar a los datos un tratamiento adecuado si estos lo llegaran a requerir. De no ser necesario omitir y pasar al siguiente paso.
- 4. **Desarrollo del método de predicción.** Esta etapa incluye las siguientes secciones:
  - a)* Selección de técnica a utilizar. Explorar distintas familias de redes neuronales y diversas técnicas de inteligencia artificial, tales como, árboles de decisión, X-GBBoost o regresión lineal.
  - b)* Elección del tipo de aprendizaje con el cual se entrenará la red, ya sea, aprendizaje supervisado o no supervisado.
  - c)* Desarrollo la arquitectura de la red.
- 5. **Entrenamiento del método de predicción.** Proporcionarle datos de entrada al método de predicción diseñado: imágenes de TC de tórax y datos sobre la CVF medida en distintas ocasiones en pacientes de FPI.
- 6. **Evaluación preliminar del método de predicción.** Detectar si existen puntos que se puedan mejorar a partir de la evaluación cuantitativa, a través de cifras de mérito, tales como, exactitud, precisión y sensibilidad.
- 7. **Ajustes al método de predicción.** En caso de ser necesario regresar al punto tres, esperando que de esta forma se eviten errores desde la parte más importante que son los datos y mejorar el desempeño del modelo si es posible. Repetir este paso las veces que sea necesario.

8. **Evaluación final del método de predicción.** Validación cuantitativa mediante el cálculo de cifras de mérito: exactitud, precisión y sensibilidad.
9. **Análisis de resultados del método de predicción.** Analizar y reportar el funcionamiento final del algoritmo propuesto.
10. **Elaboración de tesis.** Redactar tesis de proyecto.





# Capítulo 7

## Resultados y discusión

En este apartado se muestran los hallazgos del proyecto de tesis. Los resultados son el producto de haber seguido la metodología de investigación planteada. Los resultados completos de todos los experimentos se muestra en el Anexo 1. Se estiman alrededor de 3650 horas de uso del equipo de cómputo lo que equivale a aproximadamente a 5 meses de entrenamiento continuo de los experimentos. Es importante destacar el alto coste computacional que tuvo este proyecto.

En la experimentación se buscó mejorar el valor de  $LLL_m$  reportado en el estado del arte. A continuación se muestra en la Figura 7.1 un diagrama de flujo estructurado en tres etapas principales, que describen los pasos del proceso de investigación para predecir el daño pulmonar. Cada etapa está contenida dentro de un rectángulo con esquinas redondeadas, y se distinguen por colores diferenciados: azul claro, morado y verde. Dentro de cada etapa, hay cajas más pequeñas que detallan actividades específicas o componentes del proceso. Las cajas están conectadas por flechas que indican la secuencia del flujo de trabajo.

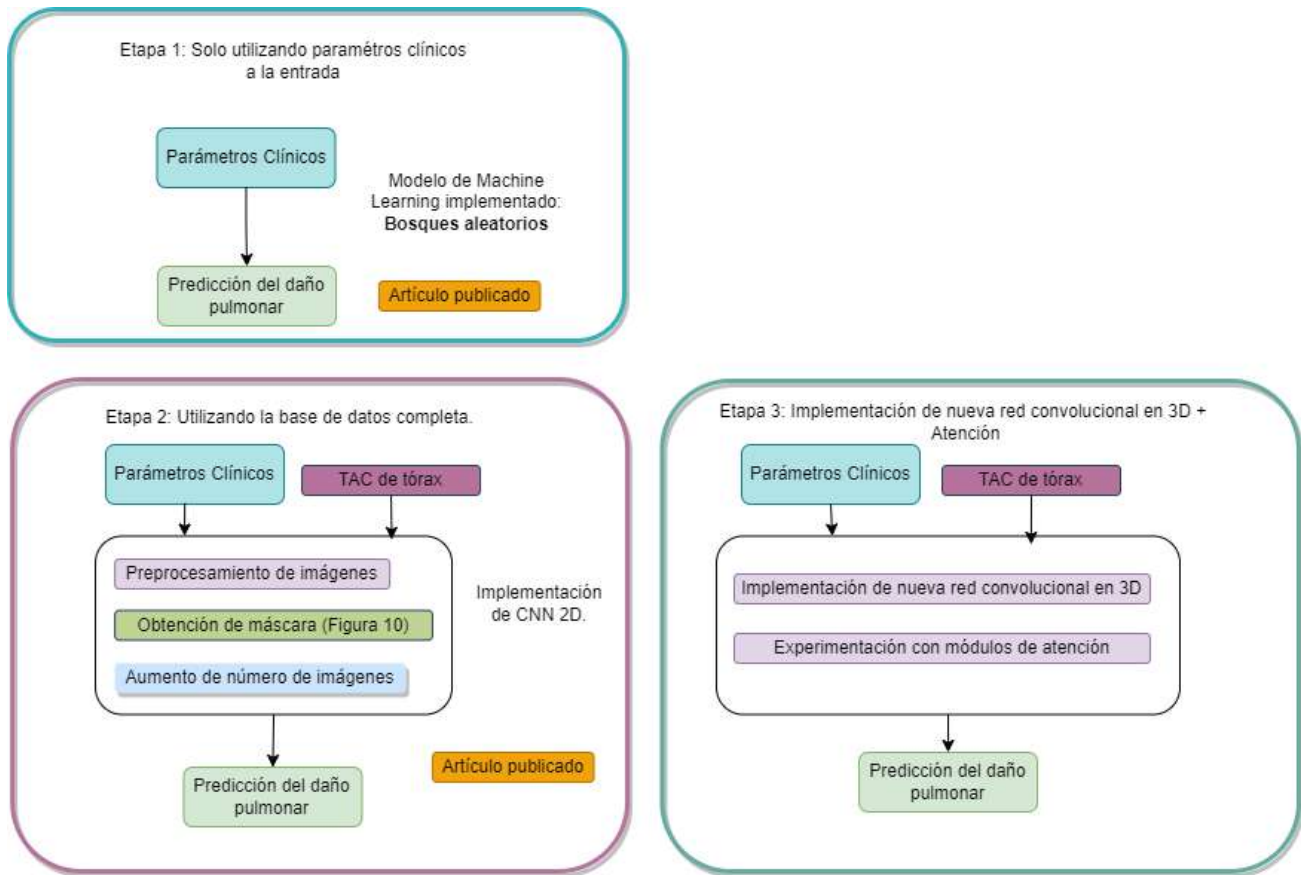


Figura 7.1: Arquitectura el modelo de predicción.

Etapa 1 (en azul): - Se centra en el uso exclusivo de parámetros clínicos. - Los parámetros clínicos se introducen en un modelo de machine learning implementado, específicamente bosques aleatorios. - Esto conduce a la predicción del daño pulmonar. - Relacionado a esta etapa se publicaron dos artículos [38, 39] lo que implica que los resultados o métodos de esta etapa han sido documentados formalmente.

Etapa 2 (en morado): - Utiliza una base de datos completa, combinando parámetros clínicos con TAC (Tomografía Axial Computarizada) de tórax. - Se detallan pasos como el preprocesamiento de imágenes, y el aumento del número de imágenes. - Implementa una CNN 2D (Red Convolutacional en 2 Dimensiones). - Esta etapa también culmina en la predicción del daño pulmonar y la publicación de los resultados en [40].

Etapa 3 (en verde): - Describe la implementación de una nueva red convolucional en 3D

con módulos de atención. - Toma tanto parámetros clínicos como TAC de tórax. - Incluye la implementación de la red en 3D y la experimentación con módulos de atención. - Finaliza, al igual que las etapas anteriores, con la predicción del daño pulmonar.

El diagrama refleja una metodología progresiva en la que cada etapa parece construir sobre los hallazgos de la anterior, integrando más datos y técnicas avanzadas para mejorar la predicción del daño pulmonar. A continuación se realiza una descripción más detallada de cada una de las etapas:

1. Se replicó el mejor modelo existente de [33] (ver Figura 7.2), reportado en el estado del arte al momento de iniciar con este proyecto de investigación. Como función codificadora se utilizaron arquitecturas ya establecidas y pre-entrenadas, tal es el caso de: EfficientNet en sus distintas versiones -B0, B1, B2, B3 y B4-, así como ResNet -18,34,50, 101 y 152-, y ResNext -50 y 101-. Al usar este tipo de arquitecturas se tienen dos opciones: utilizarlas entrenadas con el conjunto de datos de Imagenet o no (pesos aleatorios).

Esto significa que podemos cargar y usar directamente estos modelos para tareas de clasificación de imágenes si nuestro requisito coincide con el de los modelos pre-entrenados. O también podemos usarlos para transferir aprendizaje y ajustar nuestro propio conjunto de datos.

Por lo que se decidió probar con ambas opciones:

- a) Pesos aleatorios.
- b) Pesos obtenidos con Imagenet.

A continuación se muestra la arquitectura que describe al modelo de predicción con el que se experimentó:

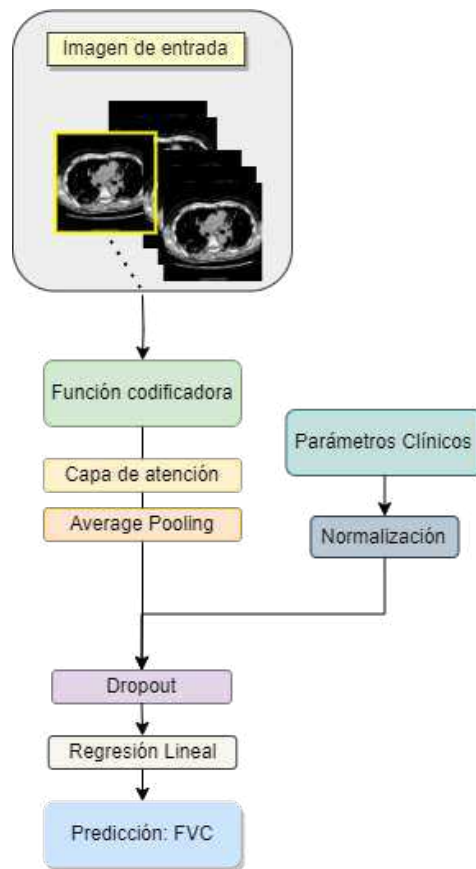


Figura 7.2: Arquitectura el modelo de predicción.

La arquitectura de la Figura 7.2 funciona de la siguiente manera: se tiene un conjunto de cortes (imágenes) de cada estudio de tomografía de cada paciente, del cual aleatoriamente se selecciona una imagen -excluyendo los cortes del inicio y final, dado que estos podrían contener menor información del área pulmonar; dicha imagen es el dato de entrada a una función codificadora pre-entrenada, recibiendo cierto tipo de atención, pasando posteriormente a una operación de *averagepooling*, resultando un un vector de características, el cual se concatena con el vector de entrada normalizado de los parámetros clínicos de entrada. A dicho vector concatenado se le aplica un *dropout* y finalmente una técnica de regresión lineal para realizar la predicción de valores de FVC.

2. Continuando con la arquitectura anterior, ahora se probaron distintos formatos y di-

mensiones para las imágenes de entrada en la red mostrada en la Figura 7.2

- a) Imagen en formato png con dimensiones: 128x128x10.
- b) Imagen en formato png en unión con la máscara, obteniendo como resultado una imagen guía de dimensiones: 128x128x10. La máscara fue obtenida del módulo mostrado en la Figura 7.3. Los detalles del módulo de segmentación se muestran en el Anexo 2.

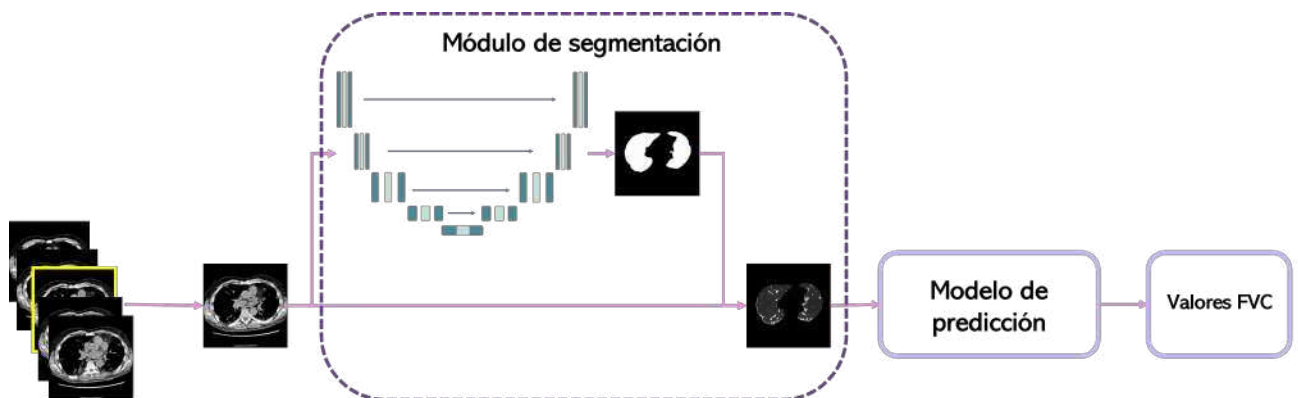


Figura 7.3: Módulo de segmentación.

- c) Imagen en formato png con dimensiones: 256x256x10.
3. En la última etapa de la red mostrada en la Figura 7.2, en la parte de predicción, se decidió realizar una modificación más: probar con distintas funciones de activación:
    - a) Tangente hiperbólica.
    - b) ReLU.
  4. En esta etapa se experimentó con transferencia de aprendizaje y aprendizaje no supervisado, es decir, se utilizaron los pesos de haber entrenado con la famosa red de aprendizaje no supervisado de Facebook, llamada SWAV. Los resultados completos se muestran en la Tablas del Anexo 01.
    - a) Transferencia de aprendizaje con SWAV entrenada con Imagenet.

- b) Transferencia de aprendizaje de SWAV entrenada con la base de datos de tomografías computarizadas de OSIC [32].

Estos resultados no fueron favorecedores por lo que se decidió no hacer mucho hincapié en esta sección de Resultados. Es importante mencionar que los resultados fueron buenos considerando que lo que se hizo fue aprendizaje no supervisado, pero no mejores que los resultados ya obtenidos con el aprendizaje supervisado (ver Tabla 7.1 y Tabla 7.2).

5. Para esta nueva etapa se aumentó el número de imágenes a la entrada de una a diez (ver Figura 7.4). Esperando que al entregarle más información a la red neuronal esta pueda aprender más, tal como funciona en el aprendizaje profundo. Para esta sección de usaron los pesos de haber pre-entrenado las funciones codificadoras con ImageNet.

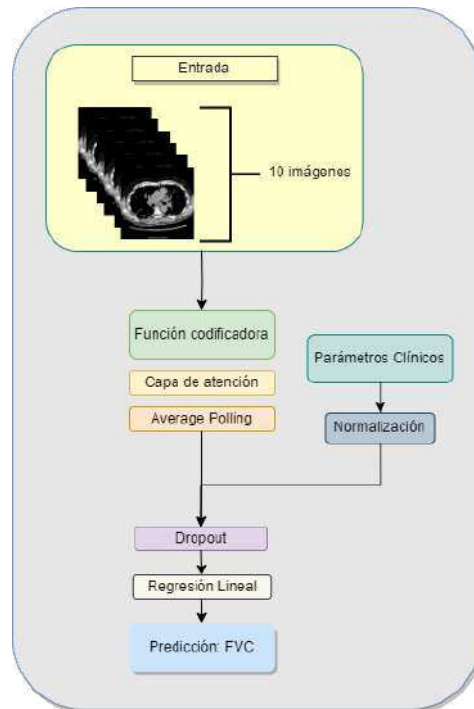


Figura 7.4: Arquitectura de la red con 10 imágenes a las entrada.

Además se realizó un aumento de datos a la entrada de la red. Básicamente un aumento de datos en imágenes para entrenamiento mediante una secuencia de transformaciones.

Estas incluyen el recorte y redimensionamiento aleatorio de la imagen a 512x512 píxeles, volteo horizontal aleatorio, rotación aleatoria de hasta 15 grados, ajustes de brillo y contraste aleatorios, transformaciones afines aleatorias (rotación y deformación), y finalmente, convierte la imagen en un tensor. Estas transformaciones simulan diversas variaciones en iluminación, orientación y perspectiva, enriqueciendo el conjunto de datos de entrenamiento y mejorando la capacidad del modelo para generalizar y manejar diversas condiciones en la inferencia.

6. Se intentó aumentando el número de imágenes a la entrada, de una a diez imágenes. Utilizando como pesos de los proporcionados por los modelos pre-entrenados con el conjunto de datos de ImageNet. Y además se probó con distintos módulos de atención:
  - a) Self attention.
  - b) Efficient Channel Attention.
  - c) Multi-Head Attention.
7. Por último, se cambiaron los módulos de convolucionales de 2 dimensiones a 3 dimensiones y se repitieron los experimentos de los puntos 5 y 6.

En las Tablas 7.1 y 7.2 se muestran los resultados de los experimentos 1.a) y 1.b) que hace referencia a utilizar los modelos de las familias de EfficientNet, ResNet y ResNext con los pesos de haber pre-entrenado con la base de datos de ImageNet. Asimismo, se muestran los resultados del experimento 3, 4, 5 y 7. En ambas Tablas, BS significa Batch Size -se refiere al tamaño de lotes-, fc: función codificadora y std: desviación estándar.

En términos generales, a partir de las Tablas 7.1 y 7.2 se puede observar que no hubo una mejoría notoria en la métrica  $LLL_m$ . Sin embargo, la diferencia más notoria existe cuando se utilizan 10 imágenes a la entrada de la red, en lugar de solo 1 imagen. Con respecto al cambio de los módulos de conv2D por conv3D, no se pudo aplicar a todos los tamaños de Batch Size debido a las limitantes del hardware, dado que al ser convoluciones en tres dimensiones requieren tener un mayor costo computacional.



Tabla 7.1: Valores de  $LL_m$  utilizando modelos predicción de la familia de EfficientNet como funciones codificadoras en cada uno de los experimentos.

Arquitectura	Batch Size	EfficientNet B0		EfficientNet B1		EfficientNet B2		EfficientNet B3		EfficientNet B4	
		$LL_m$	$std$	$LL_m$	$std$	$LL_m$	$std$	$LL_m$	$std$	$LL_m$	$std$
fc: ImageNet	10	6.7194671	0.2780267	6.7272661	0.2454186	6.6991098	0.256042	6.7195543	0.2907819	6.7282588	0.2561179
fc: ImageNet, solo cambia al final agregar TANH	10	6.70176556	0.26200207	6.73651253	0.31216732	6.71568728	0.26068268	6.7548122	0.32128502	6.71625319	0.25614637
fc: ImageNet, solo cambia al final agregar ReLU	10	6.73683929	0.30804704	6.74252426	0.28188303	6.71570681	0.24798918	6.76841429	0.25855164	6.73557451	0.2863069
fc: pesos aleatorios [RN50]	4	6.74112251	0.25108674	6.72536968	0.288745	6.69234728	0.26106347	6.77324138	0.33342074	6.74767698	0.28380312
fc(TL: SWAV con ImageNet) [RN50]	4	6.74463396	0.26319637	6.72003501	0.26928962	6.69626442	0.27696715	6.71787315	0.29440962	6.81894642	0.3570053
fc(TL: SWAV con CT) [RN50]	4	6.74463396	0.26319637	6.72003501	0.26928962	6.69626442	0.27696715	6.71787315	0.29440962	6.73764835	0.3570053
fc: ImageNet + 10 imgs/paciente	4	6.71437211	0.28667284	6.71303159	0.31882328	6.69798373	0.28416562	6.69794406	0.28744711	6.69092581	0.27416137
fc: ImageNet + 10 imgs/paciente	6	6.7348897	0.28083403	6.70669971	0.26172581	6.71562051	0.30363981	6.7256828	0.31241909	6.72051082	0.24842301
fc: ImageNet + 10 imgs/paciente	10	6.72027727	0.29340172	6.69796786	0.25596391	6.72293853	0.26306822	6.73351046	0.26498946	6.71409207	0.2455804
fc: ImageNet + 10 imgs/paciente + Data augmentation	4	6.76231111	0.2666518	8.00751201	1.31006461	6.9144984	0.32138792	6.82048992	0.29316329	6.75624559	0.2743091
fc: ImageNet + 10 imgs/paciente + Data augmentation	6	6.80780214	0.24908218	6.7800033	0.25200514	6.73225501	0.22358599	6.82837345	0.27638969	6.83556289	0.36248494
fc: ImageNet + 10 imgs/paciente + Data augmentation	10	6.71380296	0.29532197	6.87225598	0.30682248	6.70794045	0.27062549	6.8452364	0.19237737	6.79045114	0.34845942
fc: ImageNet + conv3d	10	6.72027727	0.29340172	6.69796786	0.25596391	6.72293853	0.26306822	6.73351046	0.26498946	6.73259399	0.24787878

Tabla 7.2: Valores de  $LLLM$  utilizando modelos predicción de la familia de ResNet y ResNext como funciones codificadoras en cada uno de los experimentos.

Arquitectura	BS	Resnet18		Resnet34		Resnet50		Resnet101		Resnet152		Resnext50		Resnext101	
		$LLLM$	$std$	$LLLM$	$std$	$LLLM$	$std$	$LLLM$	$std$	$LLLM$	$std$	$LLLM$	$std$	$LLLM$	$std$
fc: ImageNet	10	6.6971085	0.2560631	6.6915081	0.2536461	6.6967173	0.2619835	6.7032339	0.2722435	6.697042	0.2568719	6.7065952	0.2468298	6.7010382	0.2578098
fc: ImageNet, solo cambia al final agregar TANH	10	6.69629099	0.2516789	6.71054996	0.27421975	6.69755081	0.25419706	6.70915444	0.26447956	6.73110418	0.30885542	6.74824371	0.28221006	6.70824707	0.26806391
fc: ImageNet, solo cambia al final agregar ReLU	10	6.7279107	0.28543933	6.71683199	0.24366506	6.72841012	0.26419529	6.7063251	0.25062629	6.74047407	0.28143714	6.69295639	0.26080589	6.73144178	0.25395846
fc: pesos aleatorios [RN50]	4	6.70433023	0.24337922	6.70344409	0.27523367	6.6979111	0.24693229	6.70288172	0.27928638	6.69693615	0.24764333	6.71141736	0.25482303	6.71348446	0.26854614
fc(TL: SWAV con ImageNet) [RN50]	4	6.71705262	0.29115769	6.74474123	0.32321307	6.71002954	0.27660047	6.70716953	0.2695057	6.7220436	0.27153505	6.73552626	0.2934855	6.70877629	0.27413946
fc(TL: SWAV con CT) [RN50]	4	6.71705262	0.29115769	6.74474123	0.32321307	6.71002954	0.27660047	6.70716953	0.2695057	6.7220436	0.27153505	6.73552626	0.2934855	6.70877629	0.27413946
fc: ImageNet + 10 imgs/paciente	4	6.68485585	0.26421861	6.72477308	0.27988314	6.72029972	0.28946021	6.78119287	0.26009561	6.69849047	0.28333217	6.71001355	0.28338129	6.70312144	0.28089941
fc: ImageNet + 10 imgs/paciente	6	6.68727971	0.26443832	6.70971224	0.26219043	6.73173272	0.27673549	6.71905441	0.27104922	6.71629708	0.25412952	6.71370577	0.26583372	6.72012546	0.27179285
fc: ImageNet + 10 imgs/paciente	10	6.72134974	0.24834462	6.73258277	0.24405731	6.72147848	0.28583157	6.73005256	0.2779181	6.74240379	0.19863604	6.70920366	0.22513654	6.73737755	0.26000431
fc: ImageNet + 10 imgs/paciente + Data augmentation	4	7.47121903	1.26702009	7.48407753	1.32380238	7.13506288	0.97853896	6.97432666	0.55021564	6.88804553	0.20986801	8.16067182	2.43269384	7.92915022	2.35741784
fc: ImageNet + 10 imgs/paciente + Data augmentation	6	6.8337647	0.28504629	7.68697481	1.27467433	6.87258201	0.21667218	7.32932523	0.97605327	7.17258924	0.39256388	8.2917028	3.03158392	7.18109381	0.75243804
fc: ImageNet + 10 imgs/paciente + Data augmentation	10	6.75172633	0.26029512	6.74135189	0.22588442	7.33802479	0.57085855	7.09199582	0.38863463	7.476639	1.11327706	7.60544108	1.24939989	7.05254536	0.3024133
fc: ImageNet + conv3d	10	6.72134974	0.24834462	6.73258277	0.24405731	6.72147848	0.28583157	6.73005256	0.2779181	6.74240379	0.19863604	6.70920366	0.22513654	6.73737755	0.26000431

En esta nueva etapa se cambió completamente la arquitectura de la red, se implementó una nueva red convolucional en tres dimensiones como se muestra en la Figura 7.5:

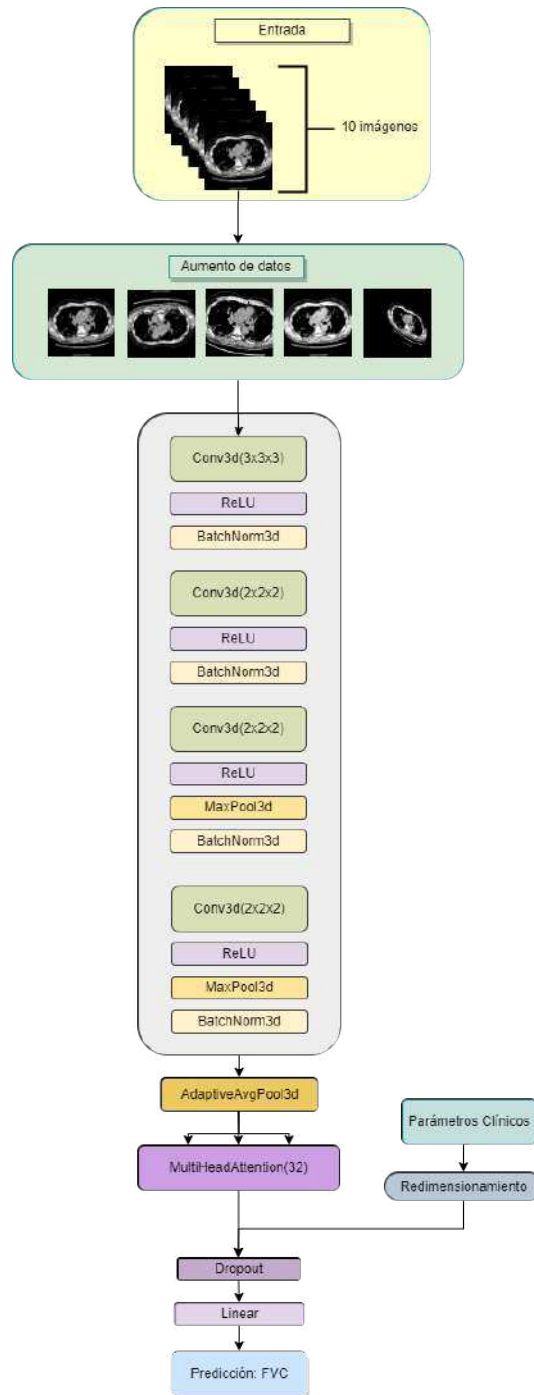


Figura 7.5: Arquitectura de modelo de predicción propuesto.

La arquitectura del modelo de predicción propuesto mostrada en la Figura 7.5 es el diseño de una red neuronal para una tarea combinada que involucra datos de imágenes de tomografía computarizada (CT) y datos tabulares. La red incorpora capas convolucionales para el procesamiento de datos CT, un mecanismo de auto-atención con múltiples cabezas para la agregación de características y capas totalmente conectadas para realizar predicciones.

Las capas convolucionales (conv1, conv2, conv3 y conv4) procesan los datos de imagen CT de entrada aplicando convoluciones 3D con activación ReLU y normalización por lotes, reduciendo gradualmente las dimensiones espaciales y aumentando los canales.

La auto-atención con múltiples cabezas (attn) se utiliza para capturar relaciones complejas dentro de los mapas de características CT. Opera en tensores de características remodelados y permutados, aplicando mecanismos de atención múltiples veces (número de capas de atención) para mejorar la representación y la agregación de características.

Los datos tabulares (parámetros clínicos) se aplanan y concatenan con las características CT procesadas. Opcionalmente, se aplica una capa de eliminación (dropout) durante el entrenamiento para regularización.

Las características concatenadas luego se pasan a través de una capa lineal con una dimensión especificada, seguida de otra capa lineal para producir la predicción final. La red está diseñada para una tarea de regresión, y la salida final es una única predicción numérica del parámetro médico: FVC.

A lo largo del proceso hacia adelante, los datos CT de entrada atraviesan una serie de transformaciones y remodelaciones, incluyendo transposiciones, remodelaciones y concatenación, para combinar de manera efectiva la información tanto de CT como tabular.

Se experimentó con esta nueva red convolucional 3D con tres distintos módulos de atención:

1. Self attention.
2. Efficient Channel Attention.
3. Multi-Head Attention.

a) Se probaron distintos números de cabeza.

- 1) Se aplicó aumento de datos a la entrada.
- 2) Se aplicó regularización L2.

Se llevaron a cabo todas las pruebas con tres tamaños diferentes de lote (batch size, BS), a saber: 4, 6 y 10. En los experimentos, se aplicó un valor de dropout de 0.25 de manera uniforme. Además, cada una de las arquitecturas empleadas tiene como entrada las imágenes guías, que corresponden a la salida del módulo de segmentación (véase Figura 7.3). Estos experimentos se ejecutaron utilizando dimensiones de entrada (DE) de 128x128x10, ya que se encontró que trabajar con dimensiones mayores resultaba en una restricción en la capacidad de la memoria gráfica.

En la segunda columna de la Tabla 7.3, se adoptó la abreviatura: MHA, seguida de un guión bajo y un número, el cual indica la cantidad de cabezas empleadas en el módulo de Atención Multi-Cabeza (*Multi-Head Attention*); mientras que el módulo de Atención Eficiente de Canales (*Efficient Channel Attention*) se identifica como: ECA. Por otro lado, el módulo de Autoatención (*Self-Attention*) se denota como: SA.

Tabla 7.3: Valores de  $LLL_m$  utilizando la arquitectura de la Figura 7.5 y los experimentos del punto 8.

Arquitectura	Módulo de atención	DE	BS	$LLL_m$	<i>std</i>
CNN 3D	MHA_16	(128x128x10)	4	6.70562611	0.26858254
CNN 3D	MHA_32	(128x128x10)	4	6.70125371	0.25920825
CNN 3D + Data Augmentation	MHA_32	(128x128x10)	4	6.70672098	0.31043359
CNN 3D + Data Augmentation	MHA_32	W (128x128x10)	4	6.68961461	0.25637081
CNN 3D + Data Augmentation	MHA_32	(512x512x10)	4	-	-
CNN 3D + Data Augmentation + L2	MHA_32	(128x128x10)	4	6.7126756	0.32503528
CNN 3D + Data Augmentation + L2	MHA_32	(128x128x10)	4	6.69093252	0.26794158
CNN 3D	MHA_32	(128x128x10)	2	6.70288652	0.25560255
CNN 3D	SA	(128x128x5)	4	6.78775222	0.28468957
CNN 3D	SA	(128x128x10)	4	6.78243745	0.24264442
CNN 3D	ECA	(128x128x10)	4	6.79448569	0.28468244

CNN 3D	MHA_1	(128x128x10)	4	6.77580312	0.31704707
CNN 3D + Data Augmentation	MHA_32	(128x128x10)	4	6.75114634	0.28835181

A partir de los resultados presentados en la Tabla 7.3, se evidencia que el valor de  $LLL_m$  más alto se logra mediante la implementación de la arquitectura propuesta para una red neuronal convolucional 3D. Esta configuración incluye el enriquecimiento de los datos de entrada mediante la incorporación de 10 imágenes y la técnica de aumento de datos, empleando el módulo de atención MHA con 32 cabezas. Las imágenes de entrada tienen dimensiones de 128x128x10, y se opera con un tamaño de lote de 4.

Es relevante destacar que esta aproximación difiere del enfoque convencional en el estado del arte, en el cual se emplean imágenes de entrada más grandes (512x512x1). Esta variación se debe a la utilización de convoluciones 3D en este estudio, lo cual conlleva un incremento en las demandas computacionales. Por esta misma razón, se aumentó el número de cabezas en el módulo de atención. Cabe señalar que, debido a restricciones de hardware, no fue factible ejecutar pruebas con imágenes de dimensiones 512x512x10.

Ahora bien, a continuación se muestra en gráficos el desempeño del mejor modelo a lo largo de las 40 épocas de entrenamiento y validación.

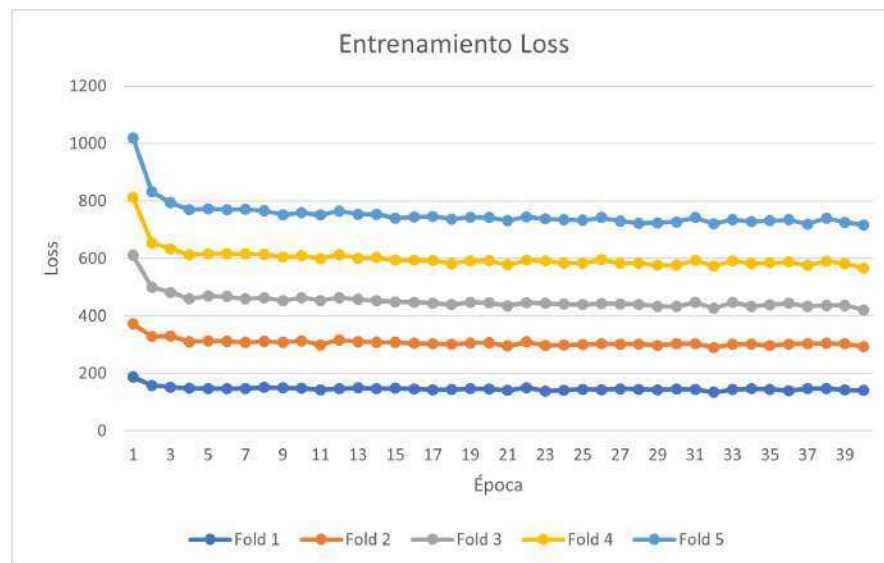


Figura 7.6: Función de pérdida durante el entrenamiento del modelo.

En la Figuras 7.6 y 7.7 se puede observar el valor de la función de pérdida "Loss" por su nombre en inglés, correspondiente a la función de pérdida L1: Error Absoluto Medio (MAE). La cual se busca que disminuya su valor durante la etapa de entrenamiento y validación.

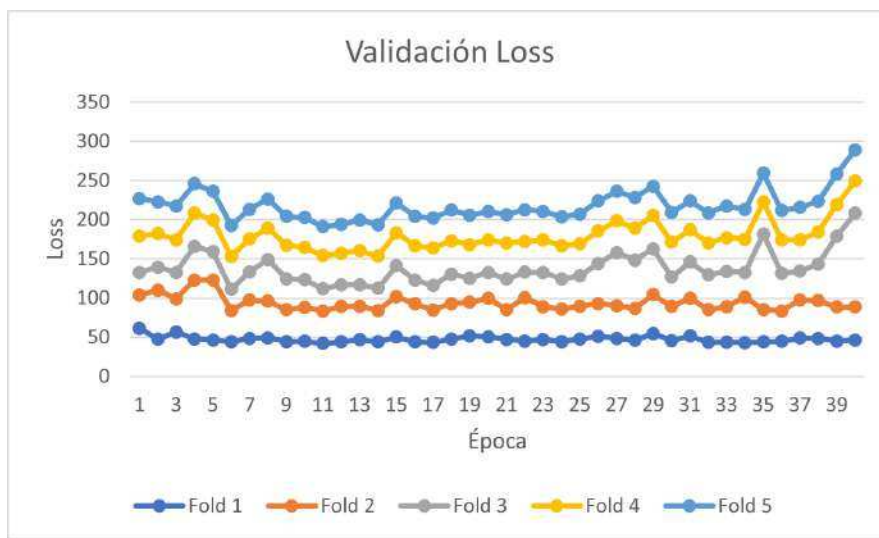


Figura 7.7: Función de pérdida durante la etapa de validación del modelo.

Asimismo, se puede observar cómo el valor de la Raíz del Error Cuadrado Medio (RMSE, por sus siglas en inglés) se comporta durante el entrenamiento del modelo de predicción. Dicho valor también se busca disminuirlo (ver Figura 7.8).

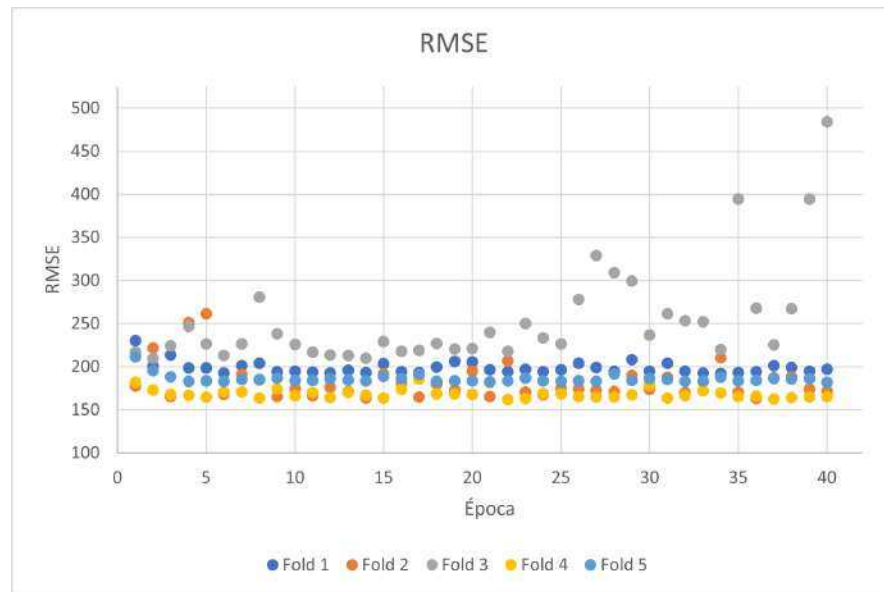


Figura 7.8: Valor de RMSE durante el entrenamiento del modelo.

En la Figura 7.9 se puede observar mediante el gráfico de dispersión de puntos cómo el valor de la métrica  $LLL_m$  se comporta durante el entrenamiento de la red de predicción. Este valor es el que se busca aumentar, dado que es el principal indicador de confianza de la predicción.



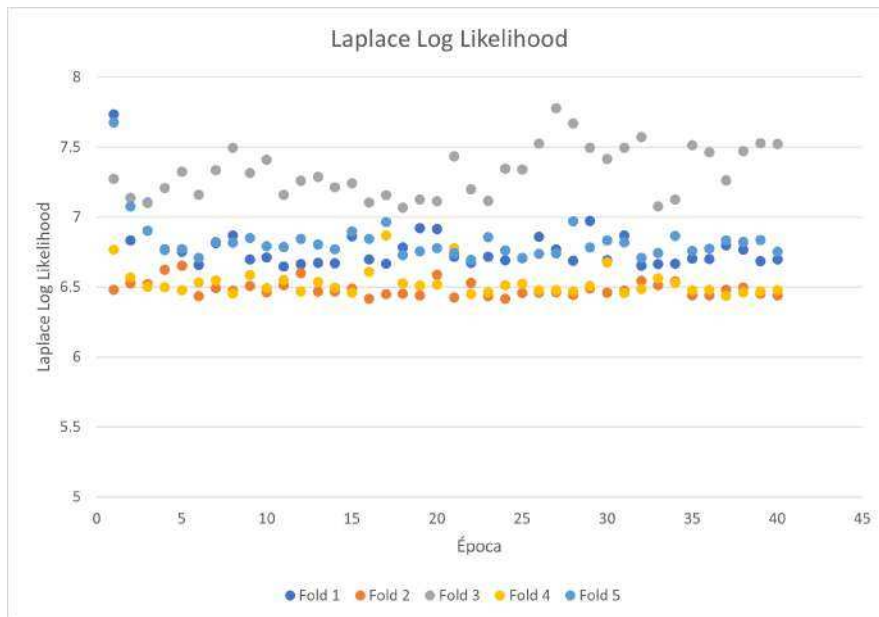


Figura 7.9: Valor de  $LLL_m$  durante el entrenamiento del modelo.

# Capítulo 8

## Conclusiones

La presente tesis representa un paso significativo hacia la comprensión y predicción del daño pulmonar causado por la fibrosis pulmonar idiopática (FPI). A través de la aplicación de técnicas de aprendizaje profundo, específicamente el uso de redes neuronales convolucionales en tres dimensiones (3D), se ha abordado un vacío en la investigación médica relacionada con esta enfermedad.

La hipótesis inicial de que la combinación de datos clínicos, imágenes de tomografías computarizadas de tórax y la aplicación de técnicas de aprendizaje profundo permitiría conocer la evolución del daño pulmonar en pacientes con FPI ha sido respaldada por los resultados obtenidos en esta investigación. La inclusión de parámetros como edad, sexo y el estado de fumador del paciente ha permitido un análisis más completo y preciso de la enfermedad, lo que podría tener implicaciones significativas para el diagnóstico temprano y el seguimiento de la FPI.

Es importante destacar que esta tesis ha logrado romper barreras en términos de metodología. A diferencia de trabajos previos que se centraron en imágenes en dos dimensiones (2D), este estudio utilizó imágenes de tomografías computarizadas en tres dimensiones (3D), lo que aumenta la precisión de las predicciones y proporciona una perspectiva más detallada del tejido pulmonar afectado.

Los experimentos realizados en esta investigación, incluyendo la transferencia de apren-

dizaje y el aprendizaje no supervisado, han arrojado resultados prometedores y han revelado la importancia del preprocesamiento de datos en la obtención de resultados más precisos. Además, se identificó la necesidad de recursos de hardware más robustos, lo que sugiere que con una mayor capacidad computacional, se podrían alcanzar resultados aún más prometedores, especialmente en relación con la métrica  $LLL_m$ .

Es gratificante mencionar que los resultados de esta investigación han sido lo suficientemente relevantes como para generar la publicación de tres artículos científicos, lo que contribuye al avance del conocimiento en este campo y sienta las bases para futuras investigaciones en el área de la FPI y su detección temprana.

En resumen, esta tesis ha demostrado que el uso de técnicas avanzadas de aprendizaje profundo, combinando datos clínicos y de imágenes, puede ser una herramienta poderosa para comprender y predecir el daño pulmonar causado por la fibrosis pulmonar idiopática. Las implicaciones clínicas y científicas de este trabajo son significativas y abren nuevas posibilidades para el diagnóstico, seguimiento y tratamiento de esta enfermedad.

# Bibliografía

- [1] “Fibrosis pulmonar - Síntomas y causas - Mayo Clinic url = <https://www.mayoclinic.org>
- [2] A. Gimenez Palleiro and T. Franquet, “Patrones radiológicos en la enfermedad pulmonar intersticial,” *Seminarios de la Fundación Española de Reumatología*, vol. 14, no. 4, pp. 97–105, oct 2013.
- [3] C. Oliva Hernandez, D. Gomez Pastrana, J. Sirvent Gomez, O. Asensio De La Cruz, D. Alvarez Gil, V. Alzina De Aguilar, A. Andres Martin, C. Antelo Landeira, O. Asensio De La Cruz, M. I. Barrio Gomez De Agüero, J. Blanco Gonzalez, M. Bermejo Pastor, A. Bonillo Perales, M. Bosque Garcia, G. Cabrera Roca, M. Carrasco Zalvide, A. Cordon Martinez, I. Cortell Aznar, J. Elorz Lambarri, A. Escribano Montaner, J. Figueroa Mulet, D. Gomez-Pastrana Duran, M. D. Gutierrez Guerra, C. Landaluce Ugarte, S. Linan Cortes, C. Luna Paredes, M. Machuca Contreras, C. Martinez Carrasco, A. Martinez Jimeno, A. Moreno Galdo, C. Oliva Hernandez, B. Osona Rodriguez De Torres, T. Pascual Sanchez, L. Pardos Rocamora, J. Perez Frias, G. Perez Perez, E. Perez Ruiz, S. Perez Tarazona, C. Reverte Bover, A. Salcedo Posadas, J. Sanchez Jimenez, E. Sannchez Sanchez, L. Sanz Borrell A, S. Gonzalez, J. Sirvent Gomez, J. M. Tabares Lezcano, J. M. Torres Simon, M. I. Ubeda Sansano, and J. R. Villa Asensi, “Estudio de la función pulmonar en el paciente colaborador. Parte I,” *Anales de Pediatría (English Edition)*, vol. 66, no. 4, pp. 393–406, apr 2007.
- [4] “Redes neuronales convolucionales - MATLAB & Simulink.” [En línea]. Disponible: <https://la.mathworks.com/discovery/convolutional-neural-network-matlab.html>

- [5] A. Xaubet, J. Ancochea, and M. Molina-Molina, “Idiopathic pulmonary fibrosis,” *Medicina Clínica (English Edition)*, vol. 148, no. 4, pp. 170–175, 2017. [En línea]. Disponible: <https://doi.org/10.1016/j.medcle.2016.11.035>
- [6] G. DS, G. D, R. HA, A. P, S. P, D. J, and R. AB, “Idiopathic pulmonary fibrosis: Current and future treatment,” *The Clinical Respiratory Journal*, vol. 16, no. 2, pp. 84–96, 2021. [En línea]. Disponible: <https://doi.org/10.1111/crj.13466>
- [7] Á. U. P., “FIBROSIS PULMONAR IDIOPÁTICA,” *Revista Médica Clínica Las Condes*, vol. 26, no. 3, pp. 292–301, may 2015.
- [8] “Distensibilidad pulmonar.” [En línea]. Disponible: [https://www.researchgate.net/publication/310707779\\_DISTENSIBILIDAD\\_PULMONAR](https://www.researchgate.net/publication/310707779_DISTENSIBILIDAD_PULMONAR)
- [9] “¿Qué es la fibrosis pulmonar? — American Lung Association.” [En línea]. Disponible: <https://www.lung.org/espanol/salud-pulmonar-y-enfermedades/fibrosis-pulmonar>
- [10] L. Richeldi, H. R. Collard, and M. G. Jones, “Idiopathic pulmonary fibrosis,” *The Lancet*, vol. 389, no. 10082, pp. 1941–1952, may 2017.
- [11] J. R. Benito, L. Sanchez, and O. Santaella, “Tomografía axial computarizada (TAC) tri-dimensional en traumatismos cérvico-faciales por arma de fuego,” *Imagen Diagnóstica*, vol. 4, no. 2, pp. 61–62, jul 2013.
- [12] “Procedimientos de tomografía axial computarizada (TC o TAC).” [En línea]. Disponible: <https://www.radiologyinfo.org/es/ctscan>
- [13] “American Thoracic Society.” [En línea]. Disponible: <http://www.nlhhep.org/Pages/Spirometry.aspx>
- [14] “Definición de funcionamiento pulmonar - Diccionario de cáncer del NCI - Instituto Nacional del Cáncer.”
- [15] “Pruebas de la función pulmonar — NHLBI, NIH.” [En línea]. Disponible: <https://www.nhlbi.nih.gov/health-topics/espanol/pruebas-de-la-funcion-pulmonar>

- [16] R. E. Benítez-Pérez, L. Torre-Bouscoulet, N. Villca-Alá, R. F. Del-Río-Hidalgo, R. Pérez-Padilla, J. C. Vázquez-García, M. Silva-Cerón, S. Cid-Juárez, and L. Gochicoa-Rangel, “www.medigraphic.org.mx espirometría: recomendaciones y procedimiento,” *Revisión Neumol Cir Torax*, vol. 75, 2016. [En línea]. Disponible: [www.medigraphic.org.mx](http://www.medigraphic.org.mx)
- [17] “Capacidad vital forzada - Fundacion Argentina del Torax.”
- [18] “Las redes neuronales artificiales - raquel flórez lópez, josé miguel fernández fernández - google libros.”
- [19] “Definición de red neuronal convolucional — deepai.” [En línea]. Disponible: <https://deepai.org/machine-learning-glossary-and-terms/convolutional-neural-network>
- [20] “Definición de aprendizaje profundo — DeepAI.” [En línea]. Disponible: <https://deepai.org/machine-learning-glossary-and-terms/deep-learning>
- [21] “¿Qué es la inteligencia artificial (IA)? - México — IBM.” [En línea]. Disponible: <https://www.ibm.com/mx-es/cloud/learn/what-is-artificial-intelligence>
- [22] J. Hurwitz and D. Kirsch, “Machine learning ibm limited edition,” 2018. [En línea]. Disponible: <http://www.wiley.com/go/permissions>.
- [23] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, L. Kaiser, and I. Polosukhin, “Attention is all you need,” 2017.
- [24] Q. Wang, B. Wu, P. Zhu, P. Li, W. Zuo, and Q. Hu, “Eca-net: Efficient channel attention for deep convolutional neural networks,” 2019.
- [25] Y. Tian, “Lung function decline predicting using improved efficientnet,” *2022 7th International Conference on Intelligent Computing and Signal Processing (ICSP)*, pp. 924–927, 2022. [En línea]. Disponible: <https://doi.org/10.1109/ICSP54964.2022.9778391>
- [26] T. Chai and R. R. Draxler, “Root mean square error (rmse) or mean absolute error (mae)? – arguments against avoiding rmse in the literature,” *Geoscientific*

- Model Development*, vol. 7, no. 3, pp. 1247–1250, 2014. [En línea]. Disponible: <https://gmd.copernicus.org/articles/7/1247/2014>
- [27] “Vista de INTELIGENCIA ARTIFICIAL EN IMAGENOLOGÍA.” [En línea]. Disponible: <http://sriuy.org.uy/ojs/index.php/Rdi/article/view/53/63>
- [28] N. Jamshidi, E. Jonasch, M. Zapala, R. L. Korn, J. D. Brooks, B. Ljungberg, and M. D. Kuo, “The radiogenomic risk score stratifies outcomes in a renal cell cancer phase 2 clinical trial.” *European radiology*, vol. 26, no. 8, pp. 2798–2807, aug 2016.
- [29] K. Suzuki, “Overview of deep learning in medical imaging,” *Radiological Physics and Technology 2017 10:3*, vol. 10, no. 3, pp. 257–273, jul 2017. [En línea]. Disponible: <https://link.springer.com/article/10.1007/s12194-017-0406-5>
- [30] “Fibrosis pulmonar - Diagnóstico y tratamiento - Mayo Clinic.” [En línea]. Disponible: <https://www.mayoclinic.org/es-es/diseases-conditions/pulmonary-fibrosis/diagnosis-treatment/drc-20353695>
- [31] S. Mandal, V. E. Balas, R. N. Shaw, and A. Ghosh, “Prediction analysis of idiopathic pulmonary fibrosis progression from osic dataset,” *2020 IEEE International Conference on Computing, Power and Communication Technologies, GUCON 2020*, pp. 861–865, 10 2020.
- [32] O. S. I. C. (OSIC), “Osic pulmonary fibrosis progression,” Open Source Imaging Consortium (OSIC), 2020, Visited: October 2022. [En línea]. Disponible: <https://www.kaggle.com/competitions/osic-pulmonary-fibrosis-progression/overview>
- [33] Z. A. Nazi, F. R. Mashrur, M. A. Islam, and S. Saha, “Fibro-cosanet: pulmonary fibrosis prognosis prediction using a convolutional self attention network,” *Physics in Medicine and Biology*, vol. 66, no. 22, p. 225013, nov 2021. [En línea]. Disponible: <https://dx.doi.org/10.1088/1361-6560/ac36a2>

- [34] A. Wong, J. Lu, A. Dorfman, P. McInnis, M. Famouri, D. Manary, J. R. H. Lee, and M. Lynch, “Fibrosis-net: A tailored deep convolutional neural network design for prediction of pulmonary fibrosis progression from chest ct images,” *Frontiers in Artificial Intelligence*, vol. 4, 2021. [En línea]. Disponible: <https://www.frontiersin.org/articles/10.3389/frai.2021.764047>
- [35] A. Yadav, R. Saxena, A. Kumar, T. S. Walia, A. Zaguia, and S. M. M. Kamal, “Fvc-net: An automated diagnosis of pulmonary fibrosis progression prediction using honeycombing and deep learning,” 2022. [En línea]. Disponible: <https://doi.org/10.1155/2022/2832400>
- [36] A. Poulou, M. Poulos, and M. Panas, “A regression-based machine learning approach for the prediction of lung function decline,” pp. 1–5, 2022.
- [37] H. B. T. Anh, T. T. Dinh, L. T. Van, and H. Le Minh, “A combined cnn-lstm and lstm-grnn model for prediction of idiopathic pulmonary fibrosis progression using ct scans and clinical data,” pp. 71–76, 2022.
- [38] S. Leyva López, E. Mena-Camilo, G. Hernández-Nava, and S. Salazar-Colores, *DESARROLLO DE UNA HERRAMIENTA DE DIAGNÓSTICO TEMPRANO DE DAÑO PULMONAR BASADA EN APRENDIZAJE AUTOMÁTICO*, 11 2023, pp. 277–283.
- [39] S. Leyva López, S. Salazar-Colores, G. Hernández-Nava, and J. C. Pedraza Ortega, *Aprendizaje Automático para la Detección del Daño Pulmonar a través de Parámetros Clínicos.*, 11 2022, pp. 262–271.
- [40] S. Leyva-López, G. Hernández-Nava, E. Mena-Camilo, and S. Salazar-Colores, “Improving idiopathic pulmonary fibrosis damage prediction with segmented images in a deep learning model,” pp. 163–165, 2023.
- [41] HFUT\_YBX, “Unet-densenet121 lung of segmentation,” Kaggle, 2020, Visited: October 2022. [En línea]. Disponible: <https://www.kaggle.com/code/hfutybx/unet-densenet121-lung-of-segmentation/notebook>





## **Capítulo 9**

# **Anexo 1. Extenso de resultados experimentales**

Todos los experimentos se realizaron con un dropout de 0.25. Cuando fue el caso se uso un número de capas de atención 3.

Tabla 9.1: Experimentos y métrica RMSE con su respectiva desviación estándar obtenidas. Parte 1.

EXP	Note	input	batch size	Efb0		Efb1		Efb2		Efb3		Efb4		CNN-3D	
				RMSE	std	RMSE	std	RMSE	std	RMSE	std	RMSE	std	RMSE	std
fc: pesos ImageNet		reportes .txt	10	183.7	23.55	183.96	22.89	181.5	25.88	183.28	22.87	184.86	22.6		
fc: ImageNet		original	10	183.471	20.279	184.98925	0.26472	183.942	19.955	183.019	19.7001	183.21	19.434		
fc: ImageNet, solo cambia al final agregar TANH		original	10	184.5132	20.3106	184.048309	20.48017	184.1799	20.3291	184.4555	20.87697	184.571	19.6608		
fc: ImageNet, solo cambia al final agregar ReLU		original	10	184.581	19.8058	185.733905	21.38181	186.0934	17.9427	184.0672	20.50155	185.375	19.8706		
fc: pesos aleatorios	RN50	original	4	183.5696	20.5387	182.281509	20.08719	184.6298	19.9125	183.0454	20.07388	183.447	19.9227		
fc(TL: SWAV con ImageNet)	RN50	original	4	182.8459	20.4391	183.676706	19.78354	183.4208	19.8326	182.7644	20.38115	191.846	23.1512		
fc(TL: SWAV con CT)	RN50	original	4												
fc: ImageNet + 10 imgs/paciente	Self	original	4	183.7926	19.6631	182.298079	19.44845	184.7613	20.4318	184.6845	20.63697	183.755	20.7785		
fc: ImageNet + 10 imgs/paciente	Self	original	6	182.2679	20.5252	183.361609	19.27106	184.2945	20.1807	183.6975	19.0619	183.144	19.8931		
fc: ImageNet + 10 imgs/paciente	Self	original	10	184.0187	21.022	184.19952	20.35633	183.9251	20.051	185.1186	21.15527	184.639	18.7761		
fc: ImageNet + 10 imgs/paciente	ECA	original	4	183.8419	21.0563	183.430612	20.46896	183.4614	21.0713	184.5497	20.01114	184.011	20.1971		
fc: ImageNet + 10 imgs/paciente	ECA	original	6	183.8318	20.3184	182.152907	18.4108	184.4419	20.6938	184.129	21.09383	184.446	20.2108		
fc: ImageNet + 10 imgs/paciente	ECA	original	10	185.3256	19.8595	185.004901	19.90726	185.0128	20.7542	184.7512	19.66225	185.909	18.499		
fc: ImageNet + 10 imgs/paciente	MHA	original	4	184.9066	19.7154	184.235637	20.06521	185.4186	20.8841	184.5127	20.63279	184.307	22.2455		
fc: ImageNet + 10 imgs/paciente	MHA	original	6	184.3799	21.4759	183.97146	20.87647	184.6076	21.3271	185.4157	20.94587	185.616	21.5364		
fc: ImageNet + 10 imgs/paciente	MHA	original	10	184.5182	21.0988	185.404006	21.06971	183.9804	20.3843	186.0241	20.753	183.447	21.2146		
fc: ImageNet + 10 imgs/paciente + Data augmentation		original	4	184.3261	19.082	185.074317	20.47836	185.1977	20.7935	185.0421	22.764	183.377	19.4267		
fc: ImageNet + 10 imgs/paciente + Data augmentation		original	6	183.1077	20.0023	185.759843	22.1519	184.109	20.4595	184.0422	20.69418	182.195	19.5059		
fc: ImageNet + 10 imgs/paciente + Data augmentation		original	10	183.2183	19.9759	183.128017	19.71891	184.3673	20.0364	184.5656	21.50748	186.529	20.4014		
fc: ImageNet + conv3d		original	10												
fc: ImageNet + 3DCNN	Self	original(128x128x5)	4											190.1414	21.7113
fc: ImageNet + 3DCNN	Self	original(128x128x10)	4											191.0531	22.53171
fc: ImageNet + 3DCNN	ECA	W (128x128x10)	4											190.1376	22.64776
fc: ImageNet + 3DCNN	MHA_1	W (128x128x10)	4											190.0964	23.22215
fc: ImageNet + 3DCNN	MHA_4	W (128x128x10)	4											189.034	23.91308
fc: ImageNet + 3DCNN	MHA_4	W (128x128x10)	4											189.4112	21.64855
fc: ImageNet + 3DCNN	MHA_1	W (256x256x10)	4											184.6705	18.94216
fc: ImageNet + 3DCNN	MHA_4	W (256x256x10)	4											185.3254	19.56402
fc: ImageNet + 3DCNN	MHA_1	W (256x256x10)	6											185.4855	19.93975
fc: ImageNet + 3DCNN	MHA_8	W (256x256x10)	4											184.0598	17.96669
fc: ImageNet + 3DCNN	MHA_16	W (256x256x10)	4											182.6745	17.79641
fc: ImageNet + 3DCNN	MHA_16	W (128x128x10)	4											182.0643	18.28091
fc: ImageNet + 3DCNN	MHA_32	W (128x128x10)	4											183.3127	18.44757
fc: ImageNet + 3DCNN	MHA_32	W (128x128x10)	2											181.6589	19.56251
fc: ImageNet + 3DCNN + Data Augmentation		W (128x128x10)	4											183.5062	18.75229
fc: ImageNet + 3DCNN + Data Augmentation + L2		W (128x128x10)	2												
fc: ImageNet + 3DCNN	MHA_1	W (512x512x10)	4												
fc: ImageNet + 3DCNN	MHA_1	W (128x128x10)	10											191.6258	22.31458

EXP	Note	input	batch size	Eifb0		Eifb1		efb2		efb3		efb4		CNN-3D	
				RMSE	std	RMSE	std	RMSE	std	RMSE	std	RMSE	std	RMSE	std
fc: ImageNet		NON-W	10	183.061	21.014	183.79035	21.0981	183.085	19.738	184.114	22.2359	185.25	20.387		
fc: ImageNet + 10 imgs/paciente		NON-W	4	184.2522	20.3493	183.586218	19.0335	185.3913	19.3618	185.8663	20.57042	182.357	18.8728		
fc: ImageNet + 10 imgs/paciente		NON-W	10	185.1726	18.6477	185.489271	19.62349	184.7784	19.745	185.7039	20.69922	186.841	19.172		
fc: ImageNet + 10 imgs/paciente + Data augmentation		NON-W	4	1277.564	2192.2	381.789056	304.4273	256.1837	91.585	278.5735	77.45166	192.523	23.7552		
fc: ImageNet		W	10	186.241	21.27	186.43192	19.8932	183.931	20.341	183.576	20.3359	184.46	20.027		
fc:ImageNet, solo cambia al final agregar TANH		W	10	184.0656	20.8018	183.788202	20.09444	184.6434	20.4356	184.63	20.50961	184.983	20.5595		
fc:ImageNet, solo cambia al final agregar ReLU		W	10	183.8309	19.7911	182.741832	21.37427	184.5032	21.195	186.269	19.72664	184.225	19.513		
fc: pesos aleatorios	RN50	W	4	185.9486	20.5636	184.710464	20.25349	182.1167	21.5363	184.9832	19.74086	185.246	20.283		
fc(TL: SWAV con ImageNet)	RN50	W	4	183.5124	19.6216	181.905807	17.74805	182.7861	19.7032	183.6408	19.9936	190.17	22.1155		
fc(TL: SWAV con CT)	RN50	W	4	183.5124	19.6216	181.905807	17.74805	182.7861	19.7032	183.6408	19.9936	190.17	22.1155		
fc: ImageNet + 10 imgs/paciente		W	4	183.2737	21.1676	182.590306	21.55149	182.7805	22.0061	180.8376	20.95459	186.279	20.0468		
fc: ImageNet + 10 imgs/paciente		W	6	185.2063	19.4782	182.916673	20.1997	183.4275	19.2549	182.7118	21.59777	184.133	19.5405		
fc: ImageNet + 10 imgs/paciente		W	10	183.2061	19.7733	183.909578	21.97055	185.5751	19.6377	183.498	20.36714	184.371	20.4696		
fc: ImageNet + 10 imgs/paciente + Data augmentation		W	4	188.1248	23.2024	511.249203	405.2166	189.4771	17.2328	236.5055	49.26965	186.43	16.4931		
fc: ImageNet + 10 imgs/paciente + Data augmentation		W	6	203.0684	23.7109	225.091266	42.25848	210.7108	67.8866	215.8044	27.64476	190.001	21.519		
fc: ImageNet + 10 imgs/paciente + Data augmentation		W	10	181.4595	20.3522	216.853376	35.28843	185.8104	23.1609	288.3829	131.4879	186.747	20.1889		
fc: ImageNet + conv3d		W	10	183.2061	19.7733	183.909578	21.97055	185.5751	19.6377	183.498	20.36714	184.973	20.4038		
fc: ImageNet + 3DCNN	Self	W (128x128x5)	4											190.1414	21.7113
fc: ImageNet + 3DCNN	Self	W (128x128x10)	4											192.2459	21.37264
fc: ImageNet + 3DCNN	ECA	W (128x128x10)	4											188.2455	26.32434
fc: ImageNet + 3DCNN	MHA	W (128x128x10)	4											188.3254	26.54211
fc: ImageNet + 3DCNN	MHA_32	W (128x128x10)	4											183.8897	19.03421



fc: ImageNet + 10 imgs/paciente	NON-W	10	186.9285	19.18004	187.0317	20.578	186.16079	19.090262	184.337897	20.279305	185.845551	20.117939
fc: ImageNet + 10 imgs/paciente + Data augmentation	NON-W	4	201.7426	10.01003	227.1449	86.0007	326.43964	263.959777	207.774683	29.724709	257.307272	103.49887
fc: ImageNet	W	10	184.749	20.5973	185.307	21.424	184.3983	21.24105	183.54692	0.272244	184.27031	20.79307
fc: ImageNet, solo cambia al final agregar TANH	W	10	184.2861	20.74561	184.0832	20.245	184.61812	20.673644	184.204058	20.468868	184.156417	20.299889
fc: ImageNet, solo cambia al final agregar ReLU	W	10	184.4992	20.0725	184.0122	20.1897	184.98832	20.0984	184.455523	20.445619	184.65142	19.241807
fc: pesos aleatorios	RN50	4	185.1259	20.21135	184.4263	20.9182	184.42721	20.986238	183.831313	19.770065	183.689661	20.54431
fc(TL: SWAV con ImageNet)	RN50	4	184.5372	20.46456	183.7498	21.3174	183.478	20.661066	183.700947	21.041027	183.756175	20.175752
fc(TL: SWAV con CT)	RN50	4	184.5372	20.46456	183.7498	21.3174	183.478	20.661066	183.700947	21.041027	183.756175	20.175752
fc: ImageNet + 10 imgs/paciente	W	4	182.0081	22.8274	181.2379	22.0523	182.46896	21.660115	183.141836	22.539939	182.83859	21.993381
fc: ImageNet + 10 imgs/paciente	W	6	180.7136	21.98652	183.1694	21.6643	183.29891	20.25662	183.373549	19.526621	181.702626	20.694848
fc: ImageNet + 10 imgs/paciente	W	10	184.755	18.92901	184.3954	19.077	184.07754	19.13674	183.455295	17.139373	186.714195	18.421129
fc: ImageNet + 10 imgs/paciente + Data augmentation	W	4	331.7813	137.1726	397.994	222.894	278.6546	127.99079	337.328871	288.09109	299.429111	101.42867
fc: ImageNet + 10 imgs/paciente + Data augmentation	W	6	330.9185	260.3563	469.7986	415.143	335.47608	93.924893	259.946355	54.033961	360.675297	189.24963
fc: ImageNet + 10 imgs/paciente + Data augmentation	W	10	210.5909	23.22848	259.6433	83.621	973.83836	1272.608	320.144744	87.449306	586.096294	727.23089
fc: ImageNet + conv3d	W	10	6.72135	0.248345	184.3954	19.077	184.07754	19.13674	186.714195	18.421129	186.714195	18.421129
fc: ImageNet + 3DCNN	Self	4										190.1414
fc: ImageNet + 3DCNN	Self	4										192.2459
fc: ImageNet + 3DCNN	ECA	4										188.2455
fc: ImageNet + 3DCNN	MHA	4										188.3254
fc: ImageNet + 3DCNN + Data Augmentation	MHA_32	4										183.8897

Tabla 9.3: Experimentos y métrica RMSE con su respectiva desviación estándar obtenidas. Parte 2.

EXP	Note	input	batch size	resnext50			resnext101			CNN-3D			
				RMSE	std	RMSE	std	RMSE	std	RMSE	std		
fc: pesos ImageNet		reportes.txt	10	184.75	22.75	184.01	23.38	190.1414	21.7113	191.0531	22.53171	190.1376	22.64776
fc: ImageNet		original	10	184.02736	20.5499	183.326542	20.05168	190.0964	23.22215	189.034	23.91308	189.4112	21.64855
fc: ImageNet, solo cambia al final agregar TANH		original	10	184.0079644	19.61232	184.3156552	19.9007487	184.6705	18.94216	185.3254	19.56402	185.4855	19.93975
fc: ImageNet, solo cambia al final agregar ReLU		original	10	185.3748533	20.84528	185.9913283	20.5341993	184.0598	17.96669	182.6745	17.79641	182.0643	18.28091
fc: pesos aleatorios	RN50	original	4	182.8623322	20.05163	183.2308429	19.9849632	183.3127	18.44757	181.6589	19.56251	183.5062	18.72529
fc(TL: SWAV con ImageNet)	RN50	original	4	184.4338264	19.695	184.2538261	20.0755304	191.6258	22.31458	191.6258	22.31458	191.6258	22.31458
fc(TL: SWAV con CT)	RN50	original	4	183.6462066	19.26809	184.0993806	20.6478855	182.6745	17.79641	182.0643	18.28091	183.3127	18.44757
fc: ImageNet + 10 imgs/paciente	Self	original	4	183.5387228	19.11939	183.2316866	19.3078992	185.4855	19.93975	185.4855	19.93975	185.4855	19.93975
fc: ImageNet + 10 imgs/paciente	Self	original	6	183.2417292	20.16782	183.6596164	20.5410125	184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 10 imgs/paciente	Self	original	10	183.4738347	20.37275	183.1963674	19.6502923	183.3127	18.44757	181.6589	19.56251	183.5062	18.72529
fc: ImageNet + 10 imgs/paciente	ECA	original	4	184.4561205	19.76152	184.0733199	21.2388748	184.6705	18.94216	185.3254	19.56402	185.4855	19.93975
fc: ImageNet + 10 imgs/paciente	ECA	original	6	185.3869073	20.41722	183.9073347	21.4041688	184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 10 imgs/paciente	MHA	original	4	183.5829738	20.57862	184.0782199	20.5842313	183.3127	18.44757	181.6589	19.56251	183.5062	18.72529
fc: ImageNet + 10 imgs/paciente	MHA	original	6	183.6581687	21.24924	181.0909971	21.4903492	184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 10 imgs/paciente	MHA	original	10	184.967581	21.31748	185.3312894	21.9939086	184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 10 imgs/paciente + Data augmentation		original	4	490.0061491	475.7889	254.5377059	122.723817	184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 10 imgs/paciente + Data augmentation		original	6	276.7222624	100.7265	802.1380004	952.937138	184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 10 imgs/paciente + Data augmentation		original	10	188.3389849	20.61497	354.4842814	334.601549	184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + conv3d		original	10					184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 3DCNN	Self	original(128x128x5)	4					190.1414	21.7113	191.0531	22.53171	190.1376	22.64776
fc: ImageNet + 3DCNN	Self	original(128x128x10)	4					190.0964	23.22215	189.034	23.91308	189.4112	21.64855
fc: ImageNet + 3DCNN	ECA	W (128x128x10)	4					184.6705	18.94216	185.3254	19.56402	185.4855	19.93975
fc: ImageNet + 3DCNN	MHA.1	W (128x128x10)	4					184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 3DCNN	MHA.4	W (128x128x10)	4					184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 3DCNN	MHA.4	W (128x128x10)	4					184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 3DCNN	MHA.1	W (256x256x10)	4					184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 3DCNN	MHA.4	W (256x256x10)	4					184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 3DCNN	MHA.1	W (256x256x10)	6					184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 3DCNN	MHA.8	W (256x256x10)	4					184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 3DCNN	MHA.16	W (256x256x10)	4					184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 3DCNN	MHA.16	W (128x128x10)	4					184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 3DCNN	MHA.32	W (128x128x10)	4					184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 3DCNN	MHA.32	W (128x128x10)	2					184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 3DCNN	MHA.32	W (128x128x10)	4					184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 3DCNN + Data Augmentation		W (128x128x10)	2					184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 3DCNN + Data Augmentation + L2		W (128x128x10)	4					184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 3DCNN		W (512x512x10)	4					184.0598	17.96669	184.0598	17.96669	184.0598	17.96669
fc: ImageNet + 3DCNN		W (128x128x10)	10					184.0598	17.96669	184.0598	17.96669	184.0598	17.96669

EXP	Note	input	batch size	resnext50		resnext101		CNN-3D	
				RMSE	std	RMSE	std	RMSE	std
fc: ImageNet		NON-W	10	183.51023	22.4383	183.404683	21.19754		
fc: ImageNet + 10 imgs/paciente		NON-W	4	183.9333266	19.90843	183.4604457	19.235285		
fc: ImageNet + 10 imgs/paciente		NON-W	10	182.4821874	17.73084	184.3116809	20.528657		
fc: ImageNet + 10 imgs/paciente + Data augmentation		NON-W	4	573.6606609	479.2864	252.1506691	67.5597693		
fc: ImageNet		W	10	184.81699	20.853	183.378331	20.0168		
fc: ImageNet, solo cambia al final agregar TANH		W	10	184.9333367	20.13955	184.1643603	20.6148035		
fc: ImageNet, solo cambia al final agregar ReLU		W	10	183.8408341	20.7524	185.5814083	21.2599293		
fc: pesos aleatorios	RN50	W	4	184.3093215	20.11533	184.3775704	21.0595966		
fc(TL: SWAV con ImageNet)	RN50	W	4	183.7890515	20.43054	181.8350436	20.2926476		
fc(TL: SWAV con CT)	RN50	W	4	183.7890515	20.43054	181.8350436	20.2926476		
fc: ImageNet + 10 imgs/paciente		W	4	182.7393398	21.46206	181.9828122	22.2066491		
fc: ImageNet + 10 imgs/paciente		W	6	183.2272014	18.64542	184.5643723	19.1838559		
fc: ImageNet + 10 imgs/paciente		W	10	183.7521682	18.99365	184.8051772	19.501709		
fc: ImageNet + 10 imgs/paciente + Data augmentation		W	4	441.1579926	410.6478	393.599416	223.28412		
fc: ImageNet + 10 imgs/paciente + Data augmentation		W	6	350.3692996	274.3133	516.6018246	599.156614		
fc: ImageNet + 10 imgs/paciente + Data augmentation		W	10	226.1262186	64.68532	499.5412975	368.307849		
fc: ImageNet + conv3d		W	10	183.7521682	18.99365	184.8051772	19.501709		
fc: ImageNet + 3DCNN	Self	W (128x128x5)	4					190.1414	21.7113
fc: ImageNet + 3DCNN	Self	W (128x128x10)	4					192.2459	21.37264
fc: ImageNet + 3DCNN	ECA	W (128x128x10)	4					188.2455	26.32434
fc: ImageNet + 3DCNN	MHA	W (128x128x10)	4					188.3254	26.54211
fc: ImageNet + 3DCNN + Data Augmentation	MHA_32	W (128x128x10)	4					183.8897	19.03421



EXP	Note	reportes.txt	batch size	Efbo	Ef1b1	efb2	efb3	efb4	std	GN-3D
				LLL	LLL	LLL	LLL	LLL	LLL	LLL
				std	std	std	std	std	std	std
fc:ImageNet			10	6.7	6.68	6.68	6.72	6.73	6.73	0.3
fc:ImageNet		original	10	6.70591	6.7250952	6.72324	6.7043	6.7025	6.7025	0.2586
fc:ImageNet, solo cambia al final agregar TANH		original	10	6.713629	6.74345192	6.696213	6.702685	6.7031	6.7031	0.25992
fc:ImageNet, solo cambia al final agregar ReLU		original	10	6.739714	6.73390997	6.755498	6.734619	6.72824	6.72824	0.23379
fc: pesos aleatorios	RN50	original	4	6.740174	6.70441108	6.697877	6.693963	6.70444	6.70444	0.26099
fc(TL: SWAV con ImageNet)	RN50	original	4	6.711488	6.7071649	6.697963	6.683289	6.75414	6.75414	0.27999
fc(TL: SWAV con CT)	RN50	original	4							
fc: ImageNet + 10 imgs/paciente	Self	original	4	6.687692	6.70370545	6.722729	6.729622	6.76252	6.76252	0.33143
fc: ImageNet + 10 imgs/paciente	Self	original	6	6.732896	6.72230391	6.723838	6.720789	6.68801	6.68801	0.25364
fc: ImageNet + 10 imgs/paciente	Self	original	10	6.728129	6.76212937	6.696853	6.714922	6.72854	6.72854	0.29454
fc: ImageNet + 10 imgs/paciente	ECA	original	4	6.722504	6.70137972	6.700543	6.724344	6.72395	6.72395	0.28413
fc: ImageNet + 10 imgs/paciente	ECA	original	6	6.742316	6.74146733	6.734103	6.73759	6.70231	6.70231	0.28474
fc: ImageNet + 10 imgs/paciente	ECA	original	10	6.734703	6.70464103	6.723427	6.718702	6.81726	6.81726	0.36455
fc: ImageNet + 10 imgs/paciente	MHA	original	4	6.731198	6.74241841	6.757432	6.728104	6.7407	6.7407	0.30207
fc: ImageNet + 10 imgs/paciente	MHA	original	6	6.738583	6.72584656	6.732172	6.744012	6.78175	6.78175	0.31054
fc: ImageNet + 10 imgs/paciente	MHA	original	10	6.759959	6.74625306	6.750786	6.775473	6.71699	6.71699	0.29674
fc: ImageNet + 10 imgs/paciente + Data augmentation		original	4	6.694227	6.76800598	6.688898	6.733316	6.69289	6.69289	0.26853
fc: ImageNet + 10 imgs/paciente + Data augmentation		original	6	6.706967	6.72127436	6.717324	6.71157	6.70308	6.70308	0.29002
fc: ImageNet + 10 imgs/paciente + Data augmentation		original	10	6.707445	6.68939988	6.724535	6.727117	6.72093	6.72093	0.26017
fc: ImageNet + conv3d		original	10							
fc:ImageNet + 3DCNN	Self	original(128x128x5)	4							0.28469
fc:ImageNet + 3DCNN	Self	original(128x128x10)	4							0.318862
ECA	ECA	W (128x128x10)	4							0.352407
MHA_1	MHA_1	W (128x128x10)	4							0.310591
MHA_4	MHA_4	W (128x128x10)	4							0.330335
MHA_4	MHA_4	W (128x128x10)	4							0.29347
MHA_1	MHA_1	Original(256x256x10)	4							0.297334
MHA_4	MHA_4	Original(256x256x10)	4							0.248585
MHA_1	MHA_1	Original(256x256x10)	6							0.285319
MHA_8	MHA_8	Original(256x256x10)	4							0.287027
MHA_16	MHA_16	Original(256x256x10)	4							
MHA_16	MHA_16	Original(128x128x10)	4							
MHA_32	MHA_32	Original(128x128x10)	4							
MHA_32	MHA_32	Original(128x128x10)	4							
MHA_32	MHA_32	Original(128x128x10)	4							
MHA_32	MHA_32	Original(128x128x10)	2							
MHA_1	MHA_1	Original(512x512x10)	4							
MHA_1	MHA_1	Original(512x512x10)	10							
fc: ImageNet		NON-W	10	6.69015	6.7383295	6.71708	6.72746	6.7292	6.7292	0.323056
fc: ImageNet + 10 imgs/paciente		NON-W	4	6.734947	6.77053697	6.739138	6.761805	6.70019	6.70019	0.27668

kernel.size.conv1 = 3—padding\_mode='replicate'—nh=4

out of memory

out fo memory

fc: ImageNet + 10 imgs/paciente	10	NON-W	6.736943	0.25519	6.77458716	0.345451	6.690348	0.27288	6.742745	0.310247	6.71107	0.25066
fc: ImageNet + 10 imgs/paciente + Data augmentation	4	NON-W	8.921984	4.44303	7.82125398	2.075424	7.126007	0.56177	7.233853	0.777734	6.87691	0.42905
fc: ImageNet	4	W	6.717427	0.26687	6.70863381	0.285697	6.706195	0.26783	6.743321	0.331967	6.7735	0.30309
fc: ImageNet	6	W	6.711175	0.29427	6.720372	0.289847	6.750557	0.27114	6.716244	0.283979	6.77874	0.31141
fc: ImageNet	8	W	6.703341	0.26966	6.69794165	0.23748	6.762036	0.32986	6.706587	0.255697	6.81127	0.34875
fc: ImageNet	8	W	6.706166	0.29582	6.74528478	0.313768	6.734312	0.27096	6.755367	0.297608	6.80356	0.32465
fc: ImageNet	10	W	6.71947	0.278	6.7272661	0.24542	6.69911	0.256	6.71955	0.29078	6.7283	0.2561
fc: ImageNet, solo cambia al final agregar TANH	10	W	6.701766	0.262	6.73651253	0.312167	6.715687	0.26068	6.754812	0.321285	6.71625	0.25615
fc: ImageNet, solo cambia al final agregar ReLU	10	W	6.736839	0.30805	6.74252426	0.281883	6.715707	0.24799	6.768414	0.258552	6.73557	0.28631
fc: pesos alatorios	4	RN50	6.741123	0.25109	6.72536968	0.288745	6.692347	0.26106	6.773241	0.333421	6.74768	0.2838
fc(TL: SWAV con ImageNet)	4	RN50	6.744634	0.2632	6.72003501	0.26929	6.696264	0.27697	6.717873	0.29441	6.81895	0.35701
fc(TL: SWAV con CT)	4	RN50	6.744634	0.2632	6.72003501	0.26929	6.696264	0.27697	6.717873	0.29441	6.73765	0.35701
fc: ImageNet + 10 imgs/paciente	4	W	6.714372	0.28667	6.71303159	0.318823	6.697984	0.28417	6.697944	0.287447	6.69093	0.27416
fc: ImageNet + 10 imgs/paciente	6	W	6.73489	0.28083	6.70669971	0.261726	6.715621	0.30364	6.725683	0.312419	6.72051	0.24842
fc: ImageNet + 10 imgs/paciente	10	W	6.720277	0.2934	6.69796786	0.255964	6.722939	0.26307	6.73351	0.264989	6.71409	0.24558
fc: ImageNet + 10 imgs/paciente + Data augmentation	4	W	6.762311	0.26665	8.00751201	1.310065	6.914498	0.32139	6.82049	0.293163	6.75625	0.27431
fc: ImageNet + 10 imgs/paciente + Data augmentation	6	W	6.807802	0.24908	6.7800033	0.252005	6.732255	0.22359	6.828373	0.27639	6.83556	0.36248
fc: ImageNet + 10 imgs/paciente + Data augmentation	10	W	6.713803	0.29532	6.87225598	0.306822	6.70794	0.27063	6.845236	0.192377	6.79045	0.34846
fc: ImageNet + conv3d	10	W	6.720277	0.2934	6.69796786	0.255964	6.722939	0.26307	6.73351	0.264989	6.73259	0.24788
fc: ImageNet + 3DCNN	4	MHA_16	W (128x128x10)								6.705626	0.268583
fc: ImageNet + 3DCNN	4	MHA_32	W (128x128x10)								6.701254	0.259208
fc: ImageNet + 3DCNN + Data Augmentation	4	MHA_32	W (128x128x10)								6.706721	0.310434
fc: ImageNet + 3DCNN + Data Augmentation	4	MHA_32	W (128x128x10)								6.689615	0.256371
fc: ImageNet + 3DCNN + Data Augmentation	4	MHA_32	W (512x512x10)									
fc: ImageNet + 3DCNN + Data Augmentation	4	MHA_32	W (128x128x10)									
fc: ImageNet + 3DCNN + Data Augmentation	4	MHA_32	W (128x128x10)									
fc: ImageNet + 3DCNN + Data Augmentation + L2	4	MHA_32	W (128x128x10)									
fc: ImageNet + 3DCNN + Data Augmentation + L2	4	MHA_32	W (128x128x10)									
fc: ImageNet + 3DCNN	2	MHA_32	W (128x128x10)									
fc: ImageNet + 3DCNN	4	Self	W (128x128x5)									
fc: ImageNet + 3DCNN	4	Self	W (128x128x10)									
fc: ImageNet + 3DCNN	4	ECA	W (128x128x10)									
fc: ImageNet + 3DCNN	4	MHA	W (128x128x10)									
fc: ImageNet + 3DCNN + Data Augmentation	4	MHA_32	W (128x128x10)									

se requieren etiquetas  
se requieren etiquetas

Tabla 9.5: Experimentos y métrica  $LL_m$  con su respectiva desviación estándar obtenidas. Parte 1.

EXP	Note	reportes .txt	batch size	Resnet18			Resnet34			Resnet50			Resnet101			Resnet152			CNN-3D		
				LLL	std	std	LLL	std	std	LLL	std	std	LLL	std	std	LLL	std	std	LLL	std	std
fc:ImageNet		original	10	6.73	0.32	0.31	6.73	0.31	0.31	6.72	0.31	0.31	6.71	0.3	6.7	0.29	6.7127101	0.274549			
fc:ImageNet		original	10	6.70869	0.2709	0.2539	6.71291	0.2539	0.244884	6.690584	0.244884	0.244884	6.7092385	0.25933	6.7092385	0.25933	6.7127101	0.274549			
fc:ImageNet, solo cambia al final agregar TANH		original	10	6.70214	0.253373	0.28832	6.724762	0.28832	0.2435603	6.6939838	0.2435603	0.2435603	6.70246472	0.271247	6.70408441	0.2684286	6.7127101	0.274549			
fc:ImageNet, solo cambia al final agregar ReLU		original	10	6.72241	0.287509	0.24583	6.733495	0.24583	0.2527794	6.7046577	0.2527794	0.2527794	6.71422284	0.2634431	6.72188834	0.2558274	6.7127101	0.274549			
fc: pesos aleatorios	RN50	original	4	6.712618	0.276762	0.27316	6.69088	0.27316	0.2439488	6.7055173	0.2439488	0.2439488	6.72139997	0.3019978	6.7197422	0.2566155	6.7197422	0.2566155			
fc(TL: SWAV con ImageNet)	RN50	original	4	6.700561	0.256675	0.25454	6.721068	0.25454	0.2596393	6.7128591	0.2596393	0.2596393	6.71433543	0.2590879	6.71022141	0.2710815	6.71022141	0.2710815			
fc(TL: SWAV con CT)	RN50	original	4																		
fc: ImageNet + 10 imgs/paciente	Self	original	4	6.725113	0.264875	0.30041	6.723715	0.30041	0.2586249	<b>6.7171638</b>	0.2586249	0.2586249	<b>6.70697942</b>	0.2594259	<b>6.69452931</b>	0.2626955	6.69452931	0.2626955			
fc: ImageNet + 10 imgs/paciente	Self	original	6	<b>6.69708</b>	0.244256	0.23754	6.724431	0.23754	0.3179874	6.735489	0.3179874	0.3179874	6.71130428	0.2530705	6.69713221	0.2422733	6.69713221	0.2422733			
fc: ImageNet + 10 imgs/paciente	Self	original	10	6.697152	0.254061	0.24221	<b>6.690066</b>	0.24221	0.25435	6.7174795	0.25435	0.25435	6.72035721	0.2633907	6.70038996	0.2485497	6.70038996	0.2485497			
fc: ImageNet + 10 imgs/paciente	ECA	original	4	6.736625	0.273706	0.26253	6.712696	0.26253	0.3026818	6.7271004	0.3026818	0.3026818	6.70504891	0.2851216	6.70403098	0.2682288	6.70403098	0.2682288			
fc: ImageNet + 10 imgs/paciente	ECA	original	6	6.72695	0.259246	0.2499	6.696207	0.2499	0.2632858	6.7131575	0.2632858	0.2632858	6.69116634	0.2648582	6.70849509	0.2888555	6.70849509	0.2888555			
fc: ImageNet + 10 imgs/paciente	ECA	original	10	6.705403	0.243547	0.24555	6.702961	0.24555	0.2519859	6.7071957	0.2519859	0.2519859	6.71576565	0.2832234	6.72583159	0.2838793	6.72583159	0.2838793			
fc: ImageNet + 10 imgs/paciente	MHA	original	4	6.721781	0.293356	0.32273	6.755087	0.32273	0.3001956	6.7254024	0.3001956	0.3001956	6.72199516	0.2974263	6.73559404	0.2953795	6.73559404	0.2953795			
fc: ImageNet + 10 imgs/paciente	MHA	original	6	6.715401	0.300006	0.32302	6.731926	0.32302	0.2978812	6.713983	0.2978812	0.2978812	6.71305195	0.3005101	6.72250848	0.3245368	6.72250848	0.3245368			
fc: ImageNet + 10 imgs/paciente	MHA	original	10	6.746624	0.302229	0.27384	6.739414	0.27384	0.2949773	6.7540129	0.2949773	0.2949773	6.75389234	0.3121535	6.72548033	0.3414004	6.72548033	0.3414004			
fc: ImageNet + 10 imgs/paciente + Data augmentation		original	4	6.802376	0.307564	0.36993	6.916427	0.36993	0.7638975	7.5891511	0.7638975	0.7638975	7.85575181	1.9111557	7.39658005	0.8456736	7.39658005	0.8456736			
fc: ImageNet + 10 imgs/paciente + Data augmentation		original	6	6.730355	0.217641	0.21247	6.76419	0.21247	1.7616694	7.7657342	1.7616694	1.7616694	6.79175901	0.2615593	6.95204392	0.2233626	6.95204392	0.2233626			
fc: ImageNet + 10 imgs/paciente + Data augmentation		original	10	6.868285	0.275511	0.23982	6.678364	0.23982	0.1384018	6.7678514	0.1384018	0.1384018	6.7678514	2.4328903	7.66133781	1.0941343	7.66133781	1.0941343			
fc: ImageNet + conv3d		original	10																		
fc:ImageNet + 3DCNN	Self	original(128x128x5)	4																	6.787752	0.28469
fc:ImageNet + 3DCNN	Self	original(128x128x10)	4																	6.771492	0.318862
fc: ImageNet + 3DCNN	ECA	W (128x128x10)	4																	6.78174	0.352407
fc: ImageNet + 3DCNN	MHA_1	W (128x128x10)	4																	6.753111	0.310591
fc: ImageNet + 3DCNN	MHA_4	W (128x128x10)	4																	6.774368	0.330335
fc: ImageNet + 3DCNN	MHA_4	W (128x128x10)	4																	6.74771	0.29347
fc: ImageNet + 3DCNN	MHA_1	Original(256x256x10)	4																	6.735974	0.297334
fc: ImageNet + 3DCNN	MHA_4	Original(256x256x10)	4																	6.73443	0.248585
fc: ImageNet + 3DCNN	MHA_1	Original(256x256x10)	6																	6.746025	0.285319
fc: ImageNet + 3DCNN	MHA_8	Original(256x256x10)	4																	6.722349	0.287027
fc: ImageNet + 3DCNN	MHA_16	Original(256x256x10)	4																		
fc: ImageNet + 3DCNN	MHA_16	Original(128x128x10)	4																		
fc: ImageNet + 3DCNN	MHA_32	Original(128x128x10)	4																		
fc: ImageNet + 3DCNN	MHA_32	Original(128x128x10)	4																		
fc: ImageNet + 3DCNN + Data Augmentation		Original(128x128x10)	4																		
fc: ImageNet + 3DCNN + Data Augmentation + L2		Original(128x128x10)	4																		
fc: ImageNet + 3DCNN	MHA_32	Original(128x128x10)	2																		
fc: ImageNet + 3DCNN	MHA_1	Original(512x512x10)	4																		
fc: ImageNet + 3DCNN	MHA_1	Original(512x512x10)	10																		

kernel\_size\_conv1 = 3—padding\_mode=replicate—n=4

out of memory

out of memory

EXP	Note	batch size	Resnet18			Resnet34			Resnet50			Resnet101			Resnet152			CNN-3D	
			LLL	std	LLL	std	LLL	std	LLL	std	LLL	std	LLL	std	LLL	std	LLL	std	LLL
fc: ImageNet	NON-W	10	<b>6.69972</b>	<b>0.26402</b>	<b>6.70908</b>	<b>0.2557</b>	<b>6.69844</b>	<b>0.26313</b>	<b>6.6714697</b>	<b>0.264191</b>	<b>6.7191418</b>	<b>0.268653</b>							
fc: ImageNet + 10 imgs/paciente	NON-W	4	6.715163	0.262464	6.718594	0.25592	6.7261027	0.2702635	6.72717928	0.3004427	<b>6.71919993</b>	0.2626786							
fc: ImageNet + 10 imgs/paciente	NON-W	10	6.709144	0.254871	6.715562	0.28628	6.7654204	0.3028402	6.7340276	0.2735151	6.74417758	0.2613731							
fc: ImageNet + 10 imgs/paciente + Data augmentation	NON-W	4	6.952015	0.218443	6.698677	0.23563	7.0220087	0.5275566	7.23885965	0.5847661	6.89142999	0.2569257							
fc: ImageNet	W	4	<b>6.690215</b>	<b>0.24728</b>	<b>6.700818</b>	<b>0.28363</b>	<b>6.6906895</b>	<b>0.2667905</b>	<b>6.7044912</b>	<b>0.2755189</b>	<b>6.71755985</b>	<b>0.2624233</b>							
fc: ImageNet	W	6	6.702297	0.259608	6.703492	0.26335	6.707742	0.2682008	6.7043291	0.2766691	6.72294914	0.2828397							
fc: ImageNet	W	8	6.711536	0.27854	6.72177	0.25595	6.6941875	0.2624036	6.72336485	0.2524094	6.70846952	0.2643155							
fc: ImageNet	W	8	6.708881	0.261782	6.716804	0.25962	6.7103464	0.2448316	6.68720937	0.2461955	6.73258299	0.291192							
fc: ImageNet, solo cambia al final agregar TANH	W	10	<b>6.69711</b>	<b>0.25606</b>	<b>6.69151</b>	<b>0.2536</b>	<b>6.696717</b>	<b>0.261983</b>	<b>6.7032339</b>	<b>0.272244</b>	<b>6.697042</b>	<b>0.256872</b>							
fc: ImageNet, solo cambia al final agregar ReLU	W	10	6.696291	0.251679	6.71055	0.27422	6.6975508	0.2541971	6.70915444	0.2644796	6.73110418	0.3088554							
fc: pesos aleatorios	W	10	<b>6.727911</b>	0.285439	6.716832	0.24367	<b>6.7284101</b>	0.2641953	6.7063251	0.2506263	<b>6.74047407</b>	0.2814371							
fc(TL: SWAV con ImageNet)	RN50	4	6.70433	0.243379	<b>6.703444</b>	0.27523	6.6979111	0.2469323	<b>6.70288172</b>	0.2792864	6.69693615	0.2476433							
fc(TL: SWAV con CT)	RN50	4	6.717053	0.291158	6.744741	0.32321	6.7100295	0.2766005	6.70716953	0.2695057	6.7220436	0.271535							
fc: ImageNet + 10 imgs/paciente	RN50	4	6.717053	0.291158	6.744741	0.32321	6.7100295	0.2766005	<b>6.70716953</b>	0.2695057	<b>6.7220436</b>	0.271535							
fc: ImageNet + 10 imgs/paciente	W	4	<b>6.684856</b>	0.264219	6.724773	0.27988	<b>6.7202997</b>	0.2894602	6.78119287	0.2600956	<b>6.69849047</b>	0.2833322							
fc: ImageNet + 10 imgs/paciente	W	6	<b>6.68728</b>	0.264438	<b>6.709712</b>	0.26219	6.7317327	0.2767355	<b>6.71905441</b>	0.2710492	6.71629708	0.2541295							
fc: ImageNet + 10 imgs/paciente	W	10	6.72135	0.248345	6.732583	0.24406	6.7214785	0.2858316	6.73005256	0.2779181	6.74240379	0.198636							
fc: ImageNet + 10 imgs/paciente + Data augmentation	W	4	7.471219	1.26702	7.484078	1.3238	7.1350629	0.978539	<b>6.97432666</b>	0.5502156	<b>6.8804553</b>	0.209868							
fc: ImageNet + 10 imgs/paciente + Data augmentation	W	6	6.833765	0.285046	7.686975	1.27467	<b>6.872582</b>	0.2166722	7.32932523	0.9760533	7.17258924	0.3925639							
fc: ImageNet + 10 imgs/paciente + Data augmentation	W	10	<b>6.751726</b>	0.260295	<b>6.741352</b>	0.22588	7.3380248	0.5708585	7.09199582	0.3886346	7.476639	1.1132771							
fc: ImageNet + conv3d	W	10	6.72135	0.248345	6.732583	0.24406	6.7214785	0.2858316	6.73005256	0.2779181	6.74240379	0.198636							
fc: ImageNet + 3DCNN	MHA_16	4																	
fc: ImageNet + 3DCNN	MHA_32	4																	
fc: ImageNet + 3DCNN + Data Augmentation	MHA_32	4																	
fc: ImageNet + 3DCNN + Data Augmentation	MHA_32	4																	
fc: ImageNet + 3DCNN + Data Augmentation	MHA_32	4																	
fc: ImageNet + 3DCNN + Data Augmentation	MHA_32	4																	
fc: ImageNet + 3DCNN + Data Augmentation + L2	MHA_32	4																	
fc: ImageNet + 3DCNN + Data Augmentation + L2	MHA_32	4																	
fc: ImageNet + 3DCNN	MHA_32	2																	
fc: ImageNet + 3DCNN	Self	4																	
fc: ImageNet + 3DCNN	Self	4																	
fc: ImageNet + 3DCNN	ECA	4																	
fc: ImageNet + 3DCNN	MHA	4																	
fc: ImageNet + 3DCNN + Data Augmentation	MHA_32	4																	

se requieren etiquetas  
se requieren etiquetas

EXP	Note	batch size	Resnext50			Resnext101			CNN-3D		
			LLL	std	LLL	LLL	std	LLL	std	LLL	std
fc: ImageNet		10	6.7	0.27	6.72	0.28					
fc: ImageNet		10	<b>6.7107728</b>	<b>0.25794</b>	<b>6.7050302</b>	<b>0.256368</b>					
fc: ImageNet, solo cambia al final agregar TANH		10	6.713050719	0.284527	6.722692355	0.2907216					
fc: ImageNet, solo cambia al final agregar ReLU		10	6.720837841	0.229663	6.732726467	0.24382375					
fc: pesos aleatorios	RN50	4	6.713069365	0.286894	6.711743488	0.27121593					
fc(TL: SWAV con ImageNet)	RN50	4	6.716096007	0.271684	6.71364689	0.26390634					
fc(TL: SWAV con CT)	RN50	4									
fc: ImageNet + 10 imgs/paciente	Self	4	6.72316222	0.28122	6.711638772	0.25717274					
fc: ImageNet + 10 imgs/paciente	Self	6	<b>6.710096232</b>	0.246297	6.690680023	0.25483938					
fc: ImageNet + 10 imgs/paciente	Self	10	6.723723701	0.257024	<b>6.68988797</b>	0.25018749					
fc: ImageNet + 10 imgs/paciente	ECA	4	6.699996063	0.262988	6.72626719	0.314139668					
fc: ImageNet + 10 imgs/paciente	ECA	6	6.721508451	0.265559	6.702151019	0.26823641					
fc: ImageNet + 10 imgs/paciente	ECA	10	6.729670095	0.24795	6.703993836	0.25228177					
fc: ImageNet + 10 imgs/paciente	MHA	4	6.75939504	0.353184	6.746292177	0.28798188					
fc: ImageNet + 10 imgs/paciente	MHA	6	6.722530412	0.288834	6.703326999	0.30155142					
fc: ImageNet + 10 imgs/paciente	MHA	10	6.741357467	0.27341	6.715957994	0.30637712					
fc: ImageNet + 10 imgs/paciente + Data augmentation		4	7.036636641	0.23262	<b>6.825293442</b>	0.24745898					
fc: ImageNet + 10 imgs/paciente + Data augmentation		6	6.78508084	0.264454	7.009423755	0.39831508					
fc: ImageNet + 10 imgs/paciente + Data augmentation		10	<b>6.86745397</b>	0.491721	7.40539717	1.45572277					
fc: ImageNet + conv3d		10									
fc: ImageNet + 3DCNN	Self	4							6.787752	0.28469	
fc: ImageNet + 3DCNN	Self	4							6.771492	0.318862	
fc: ImageNet + 3DCNN	ECA	4							6.78174	0.352407	
fc: ImageNet + 3DCNN	MHA_1	4							6.753111	0.310591	
fc: ImageNet + 3DCNN	MHA_4	4							6.774368	0.330335	
fc: ImageNet + 3DCNN	MHA_4	4							6.74771	0.29347	
fc: ImageNet + 3DCNN	MHA_1	4							6.735974	0.297334	
fc: ImageNet + 3DCNN	MHA_4	4							6.73443	0.248585	
fc: ImageNet + 3DCNN	MHA_1	6							6.746025	0.285319	
fc: ImageNet + 3DCNN	MHA_8	4							6.722349	0.287027	
fc: ImageNet + 3DCNN	MHA_16	4									
fc: ImageNet + 3DCNN	MHA_16	4									
fc: ImageNet + 3DCNN	MHA_32	4									
fc: ImageNet + 3DCNN + Data Augmentation	MHA_32	4									
fc: ImageNet + 3DCNN + Data Augmentation + L2	MHA_32	4							6.715523	0.280768	
fc: ImageNet + 3DCNN	MHA_32	2							6.724352	0.290339	
fc: ImageNet + 3DCNN	MHA_1	4									
fc: ImageNet + 3DCNN	MHA_1	10									
fc: ImageNet	NON-W	10	<b>6.7097402</b>	<b>0.24967</b>	<b>6.67146974</b>	<b>0.266295</b>			6.767947	0.323056	
fc: ImageNet + 10 imgs/paciente	NON-W	4	6.726794648	0.278416	6.729382013	0.28389591					

out of memory

out of memory

out of memory

kernel\_size.conv1 = 3—padding\_mode='replicate'—nh=4





# Capítulo 10

## Anexo 2. Módulo de segmentación

En este trabajo se incorpora un modelo de segmentación semántica UNet como modulo de preprocesamiento a un algoritmo de predicción de daño pulmonar ocasionado por Fibrosis Pulmonar Idiopática. Modificando la entrada al modelo mediante la union de una imagen guía (resultado de la segmentación) a la imagen original. Los resultados mostraron una mejora en el desempeño de ocho de los doce backbones probados para el modelo de predicción, con una mejora de hasta un 0.57 en la métrica  $LLL_m$ . Este estudio resalta la importancia en el preprocesamiento de los datos en el desempeño de los modelos deep learning. La inclusión de datos adicionales, como las imágenes segmentadas, puede mejorar significativamente la capacidad de un modelo para realizar tareas específicas, lo que subraya la necesidad de un preprocesamiento cuidadoso de los datos para obtener resultados precisos y confiables en la implementación de modelos de deep learning para la predicción de daño pulmonar.

Como primer paso se selecciona aleatoriamente uno de los cortes centrales del estudio de CT, omitiendo el 15 % de los cortes iniciales y centrales. Al ser imágenes en formato DICOM, se transforma en formato PNG de dimensiones  $256 \times 256 \times 1$ , con el objetivo de optimizar el uso de la memoria gráfica de cómputo. Posteriormente, dicho arreglo es procesado por un modelo de la biblioteca *Segmentation Models PyTorch*, el cual consiste en una UNet que utiliza la arquitectura de red DenseNet121 como codificador. A esta arquitectura se le asigna un valor de uno, tanto al número de clases como al número de canales de entrada, lo que



sugiere que solo se está segmentando un objeto en la imagen y que la imagen de entrada es en escala de grises. Una vez compilado el modelo se realiza una transferencia de aprendizaje con los pesos disponibles en [41]. Como resultado de la evaluación de la entrada en el modelo anterior se obtiene una máscara, donde se segmentan los pulmones del corte de CT.

Ya que se cuenta con la máscara esta se une con la entrada original de la arquitectura para posteriormente ser procesada por la red descrita en [3].

Para finalizar se prueban diferentes funciones codificadoras dentro del módulo mostrado en la Figura 7.3, en las cuales se incluyen EfficientNet, ResNet y ResNeXt, con sus respectivas variaciones. Finalmente se calculan las métricas  $LLL_m$  y  $RMSE$ , indicadoras de la confiabilidad de las predicciones, para realizar una comparación cuantitativa entre los experimentos. Cabe mencionar que las evaluaciones y métricas calculadas fueron obtenidas mediante la técnica de 10-Fold.

Relacionado al preprocesamiento de los datos. En primer lugar, se seleccionan únicamente los cortes centrales de cada estudio de tomografía (que consta de diferentes números de cortes), omitiendo el 15 % de los cortes iniciales y finales. Cada corte o imagen se representa como un arreglo uint de 8 bits con dimensiones de (256, 256, 1) (ver Figura 7.3).

A continuación, se obtiene una máscara para cada una de las imágenes utilizando una biblioteca de Pytorch que carga un modelo de la librería Segmentation Models PyTorch (smp) para la tarea de segmentación de imágenes médicas. Se implementa una UNet que utiliza la arquitectura de red DenseNet121 como codificador, donde se establece el parámetro classes en 1 y el parámetro “in channels” en 1, lo que sugiere que solo se está segmentando un objeto en la imagen y que la imagen de entrada es en escala de grises, respectivamente (ver Figura 7.3). El modelo se carga con los pesos entrenados previamente que se encuentran disponibles en [41].

Posteriormente, se procede a la suma de las imágenes originales con su respectiva máscara (ver figura 7.3).

Para llevar a cabo la experimentación, se evalúa el rendimiento de la red [33] con distintas funciones codificadoras. En particular, se probarán las respectivas variaciones de EfficientNet, ResNet y ResNeXt. La evaluación se llevará a cabo utilizando las métricas  $LLL_m$  y

*RMSE.*

A partir de los resultados obtenidos, los cuales indican una diferencia favorable al utilizar una imagen guía a la entrada del modelo de predicción, se puede concluir que la inclusión de datos adicionales, como las máscaras obtenidas a través de modelos de segmentación, mejoran los datos de entrada a modelos y de esta forma se obtienen resultados precisos y confiables en la predicción del daño de la fibrosis pulmonar idiopática. Logrando ser utilizados como módulos de preprocesamiento para trabajos futuros.

Este trabajo se publicó en IEE-CAI Conference 2023 [40].

Tabla 10.1: Comparison of the metrics reported by the authors of Fibro-CoSAnet, those obtained after reproducing the same experiment, and after modifying the input to the network with a guided image.

f-encoder	Experiment	RMSE			LL <sub>m</sub>		
		Mean	Std	Difference from guided image	Mean	Std	Difference from guided image
Efb0	Fibro-CoSAnet	183.70	23.55	-1.38	6.70	0.29	-0.29
	Replicated Model	183.47	20.28	-1.51	6.71	0.28	-0.20
	Guided Image	186.24	21.27	-	6.72	0.28	-
Efb1	Fibro-CoSAnet	183.96	22.89	-1.34	6.68	0.28	-0.71
	Replicated Model	184.99	0.26	-0.78	6.73	0.26	-0.03
	Guided Image	186.43	19.89	-	6.73	0.25	-
Efb2	Fibro-CoSAnet	181.50	25.88	-1.34	6.68	0.31	-0.29
	Replicated Model	183.94	19.95	<b>0.01</b>	6.72	0.26	<b>0.36</b>
	Guided Image	183.93	20.34	-	6.70	0.26	-
Efb3	Fibro-CoSAnet	183.28	22.87	-0.16	6.72	0.34	<b>0.01</b>
	Replicated Model	183.02	19.70	-0.30	6.70	0.27	-0.23
	Guided Image	183.58	20.34	-	6.72	0.29	-
Efb4	Fibro-CoSAnet	184.86	22.60	<b>0.22</b>	6.73	0.30	<b>0.03</b>
	Replicated Model	183.21	19.43	-0.68	6.70	0.26	-0.38
	Guided Image	184.46	20.03	-	6.73	0.26	-
ResNet18	Fibro-CoSAnet	184.71	23.79	-0.02	6.73	0.32	<b>0.49</b>
	Replicated Model	182.50	19.38	-1.23	6.71	0.27	<b>0.17</b>
	Guided Image	184.75	20.60	-	6.70	0.26	-
ResNet34	Fibro-CoSAnet	184.79	21.45	-0.28	6.73	0.31	<b>0.57</b>
	Replicated Model	184.62	20.76	-0.37	6.71	0.25	<b>0.32</b>
	Guided Image	185.31	21.42	-	6.69	0.25	-
ResNet50	Fibro-CoSAnet	184.07	21.74	-0.18	6.72	0.31	<b>0.35</b>
	Replicated Model	183.45	20.82	-0.52	6.69	0.24	-0.09
	Guided Image	184.40	21.24	-	6.70	0.26	-
ResNet101	Fibro-CoSAnet	183.13	24.87	-0.23	6.71	0.30	<b>0.10</b>
	Replicated Model	184.44	21.20	<b>0.48</b>	6.71	0.26	<b>0.09</b>
	Guided Image	183.55	0.27	-	6.70	0.27	-
ResNet152	Fibro-CoSAnet	183.89	22.25	-0.21	6.70	0.29	<b>0.04</b>
	Replicated Model	184.23	20.45	-0.02	6.71	0.27	<b>0.23</b>
	Guided Image	184.27	20.79	-	6.70	0.26	-
ResNext50	Fibro-CoSAnet	184.75	22.75	-0.04	6.70	0.27	-0.10
	Replicated Model	184.03	20.55	-0.43	6.71	0.26	<b>0.06</b>
	Guided Image	184.82	20.85	-	6.71	0.25	-
ResNext101	Fibro-CoSAnet	184.01	23.38	<b>0.34</b>	6.72	0.28	<b>0.28</b>
	Replicated Model	183.33	20.05	-0.03	6.71	0.26	<b>0.06</b>
	Guided Image	183.38	20.02	-	6.70	0.26	-

\*The hyphen symbol is used when comparing the same experiment.

\*\*The mean and standard deviation values were obtained from the results of the 5 experiments conducted using 5-fold cross-validation, with each of the f-encoder functions.

# Capítulo 11

## Anexo 3. Análisis de la base de datos

### OSIC

Claramente, los datos son una parte esencial en el diseño de un sistema de IA. La calidad de estos datos influye directamente en el desempeño de los modelos desarrollados. En esta ocasión los datos fueron obtenidos de la plataforma Kaggle, los cuales son libres y gratuitos. La base de datos está conformada por información de 1549 pacientes con FPI, de los cuales 1224 son hombres y 325 mujeres. De cada paciente se poseen cinco parámetros clínicos: edad, sexo, CVF, la relación del paciente con el tabaco: ex-fumador, nunca ha fumado, actualmente fuma, y el porcentaje de CVF.

Con la finalidad de conocer si existe una relación entre las cinco variables descritas previamente con el daño pulmonar. Se decidió realizar un análisis basado en la correlación de Pearson. La correlación de Pearson ( $\rho$ ) mide el grado de relación lineal entre dos variables. Esta medida de correlación puede entenderse como un análisis de covarianzas normalizado. Matemáticamente, suele ser descrita en términos de la varianza ( $Var$ ) y Covarianza ( $Cov$ ), tal como se muestra en la Ecuación 11.1.

$$\rho = \frac{Cov(X, Y)}{\sqrt{Var(X)Var(Y)}} \quad (11.1)$$

En la Figura 11.1 es mostrada la matriz con los coeficientes de correlación de Pearson. Es

importante mencionar que dichos coeficientes están limitados entre -1 y 1. Donde -1 representa relaciones negativas perfectas y 1 denota relaciones positivas perfectas, mientras que, el valor intermedio 0 se presenta cuando no existe una relación entre variables. Por tanto, es posible observar en la Figura 11.1 que el sexo y el estado del fumador están mayormente relacionados con la CVF de la persona. 1.1 Preprocesamiento de los datos. Originalmente, las variables de la base de datos son descritas mediante variables numéricas y alfabéticas. Evidentemente, para hacerlos entendibles para los modelos de inteligencia artificial que se desarrollarán en este proyecto se requiere codificar los datos de tipo alfabético a numérico. La variable “sexo” fue pasada de las categorías H y M a los valores 1 y 0, respectivamente. Mientras que, el estatus de fumador fue convertido a valores 0 para el estado “fumador”, 1 para “nunca ha fumado” y 2 asignado a “actualmente fuma”. Asimismo, los atributos “Edad” y “Porcentaje” fueron normalizados.




Figura 11.1: Matriz de correlación de Pearson.

A continuación se muestra un desglose de las métricas estadísticas obtenidas de las variables contenidas en la base de datos: CVF, porcentaje de cvf, edad, Sexo y Estado del fumador.

## 11.1. CVF

### 1. Estadísticas cuantiles

- a) Mínimo: 827
- b) percentil 5: 1441
- c) Q1: 2109
- d) mediana: 2641
- e) Q3: 3171
- f) percentil 95: 4178.6
- g) Máximo: 6399
- h) Rango: 5572
- i) Rango intercuartílico (RIC): 1062

### 2. Estadísticas descriptivas

- a) Desviación estándar: 832.7709593
- b) Coeficiente de variación (CV): 0,3095251639
- c) Curtosis: 0.5719853718
- d) Media: 2690.479019
- e) Desviación absoluta mediana (MAD): 532
- f) Asimetría: 0.5842714375
- g) Suma: 4167552
- h) Variación: 693507.4707
- i) Monotonicidad: No monótona

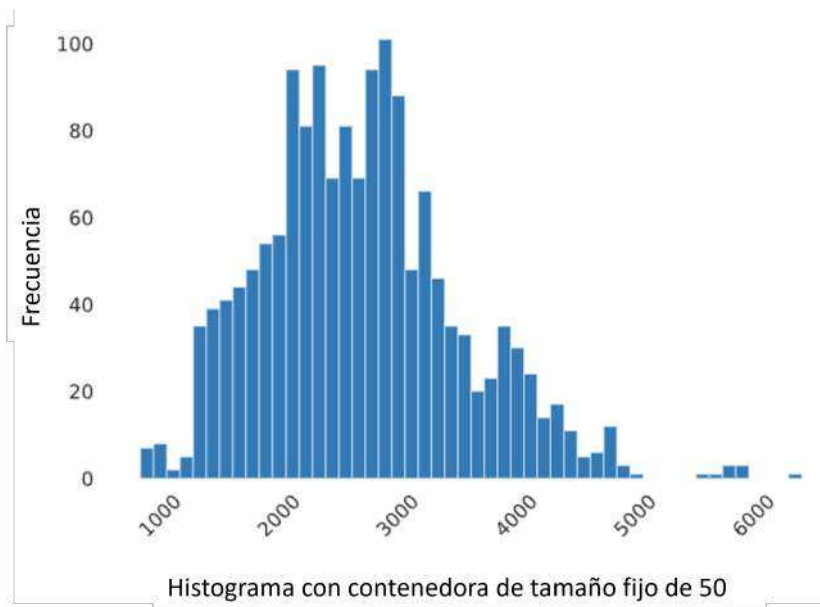


Figura 11.2: Histograma del parámetro CVF.

## 11.2. Porcentaje de CVF.




Figura 11.3: Gráfico circular del parámetro porcentaje

## 11.3. Edad

### 1. Estadísticas cuantiles

- a) Mínimo: 49
- b) percentil 5: 55
- c) Q1: 63
- d) mediana: 68
- e) Q3: 72
- f) percentil 95: 78
- g) Máximo: 88
- h) Gama: 39
- i) Rango intercuartílico (RIC): 9

### 2. Estadísticas descriptivas

- a) Desviación estándar: 7.057394616
- b) Coeficiente de variación (CV): 0,105038715
- c) Curtosis: 0.06721908163
- d) Media: 67.18850872
- e) Desviación absoluta mediana (MAD): 4
- f) Asimetría: -0.04617524698
- g) Suma: 104075
- h) Variación: 49.80681877
- i) Monotonicidad: No monótona



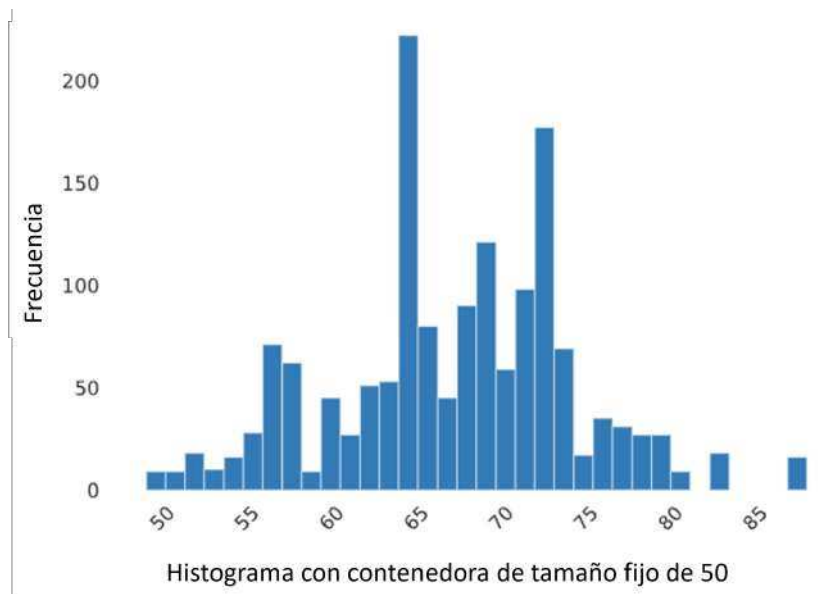


Figura 11.4: Histograma de la variables Edad.

## 11.4. Sexo




Figura 11.5: Gráfico circular de la variables sexo.

En la Figura 11.6 se puede observar que existe una mayor prevalencia de valores menores CVF en edad entre los 60 y 75 años.




Figura 11.6: Relación entre la variable Edad y CVF.

## 11.5. Estado del fumador

A partir de la Figura 11.7 se puede decir que en la base de datos existe una mayor prevalencia de pacientes que nunca han fumado.




Figura 11.7: Gráfica circular del estado del fumador.



# Capítulo 12

## Anexo 4. Actividades extracurriculares



**DIPFI**  
POSGRADO  
INGENIERÍA

UNIVERSIDAD AUTÓNOMA DE QUERÉTARO  
FACULTAD DE INGENIERÍA  
DIVISIÓN DE INVESTIGACIÓN Y POSGRADO

**VOTOS APROBATORIOS**  
DE PROTOCOLO DE TESIS

PROGRAMA DE ESTUDIOS: Maestría en Ciencias en Inteligencia Artificial

NOMBRE: LEYVA LOPEZ SHEILA

NOMBRE DE LA TESIS: Predicción del daño pulmonar ocasionado por fibrosis pulmonar idiopática mediante aprendizaje profundo en imágenes de tomografía computarizada de tórax

Elemento del protocolo	Requerimiento
Redacción y Estilo	El documento es legible, coherente y está libre de errores gramaticales. El estilo es directo, impersonal y se enfoca en las evidencias, análisis, hallazgos y resultados.
Formato	El documento se apega a la estructura y lineamientos del formato aprobado por la DIPFI.
- Título del proyecto de tesis	El título describe la esencia del trabajo en 20 palabras o menos.
- Línea de investigación	El trabajo se inserta en una de las Líneas de Generación y Aplicación del Conocimiento del programa de estudios correspondiente.
II Antecedentes	Los antecedentes describen la evaluación del conocimiento acerca del fenómeno o hecho a investigar. Se identifican el estado del arte y de la técnica relacionados con el problema bajo estudio.
III Justificación	Se aporta evidencia que demuestra la pertinencia del trabajo en el contexto de la(s) disciplina(s) del programa y la viabilidad económica y técnica del proyecto.
IV Descripción del problema	Se identifican los fenómenos, hechos o situaciones, que puestos en relación presentan incongruencia, obstáculos, desconocimiento o discrepancia y que constituyen el objeto de estudio.
V Fundamentación teórica	La Fundamentación Teórica plantea la perspectiva desde donde se desarrollará el estudio (modelo teórico, básico), los elementos del tema que consideramos más significativos (variable con las cuales va a interactuar el investigador), y los instrumentos teóricos de análisis de los datos obtenidos.
VI Hipótesis y objetivos (de acuerdo al tipo de programa)	La hipótesis es un enunciado a reglón corrido, que plantea una posible respuesta a la pregunta de investigación basada en la teoría y en la práctica, estableciendo relaciones entre las variables del problema y que al contrastarse proporcionará conocimiento nuevo en la disciplina de estudio. Los objetivos son alcanzables, específicos, medibles, realistas y tienen un plazo. Existe congruencia entre el título de la tesis, la hipótesis y los objetivos.
VII Metodología y cronograma	La metodología describe los materiales, herramientas y métodos que se usarán para verificar la hipótesis y lograr los objetivos del trabajo de investigación, a un nivel de detalle suficiente para permitir la réplica del trabajo. El cronograma está desarrollado en un diagrama de Gantt y el proyecto se puede concluir dentro de los tiempos establecidos en el programa de posgrado correspondiente.
VIII Resultados esperados, posibles aplicaciones y uso del proyecto	Se especifican los productos del trabajo, su impacto científico, tecnológico y económico.
IX Referencias bibliográficas	Las referencias son recientes, pertinentes, están citadas en el texto y se apegan al formato que sugiere la Dirección de Investigación y Posgrado de la UAQ, o el Journal of Animal Science Style and Form (Revised 2005).
<b>Elementos Éticos del Protocolo</b>	<b>Requerimiento para ser Evaluado por el Comité de Ética para la Investigación</b>
1. Aspectos generales	¿Incluye el protocolo las aclaraciones respecto Anexo II del comité de ética: Formato de Registro ante el Comité de Ética para la Investigación de la Facultad de Ingeniería de la Universidad Autónoma de Querétaro?
2. Seguridad	¿Se incluye en el protocolo una sección sobre seguridad y buenas prácticas de laboratorio que garanticen la integridad de los investigadores y participantes involucrados?

Nombre: SALAZAR COLORES SEBASTIÁN  
Puesto de sinodal: DIRECTOR DE TESIS  
Fecha: 01/03/2022 21:16



Nota: La obtención del voto aprobatorio se realiza por medio de la plataforma SAIP

Figura 12.1: Votos aprobatorios: director de tesis.



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO  
FACULTAD DE INGENIERÍA  
DIVISIÓN DE INVESTIGACIÓN Y POSGRADO

VOTOS APROBATORIOS  
DE PROTOCOLO DE TESIS

PROGRAMA DE ESTUDIOS: Maestría en Ciencias en Inteligencia Artificial  
NOMBRE: LEYVA LOPEZ SHEILA  
NOMBRE DE LA TESIS: Predicción del daño pulmonar ocasionado por fibrosis pulmonar idiopática mediante aprendizaje profundo en imágenes de tomografía computarizada de tórax

Elemento del protocolo	Requerimiento
Redacción y Estilo	El documento es legible, coherente y está libre de errores gramaticales. El estilo es directo, impersonal y se enfoca en las evidencias, análisis, hallazgos y resultados.
Formato	El documento se apega a la estructura y lineamientos del formato aprobado por la DIPFI.
- Título del proyecto de tesis	El título describe la esencia del trabajo en 20 palabras o menos.
- Línea de investigación	El trabajo se inserta en una de las Líneas de Generación y Aplicación del Conocimiento del programa de estudios correspondiente.
II Antecedentes	Los antecedentes describen la evaluación del conocimiento acerca del fenómeno o hecho a investigar. Se identifican el estado del arte y de la técnica relacionados con el problema bajo estudio.
III Justificación	Se aporta evidencia que demuestra la pertinencia del trabajo en el contexto de la(s) disciplina(s) del programa y la viabilidad económica y técnica del proyecto.
IV Descripción del problema	Se identifican los fenómenos, hechos o situaciones, que puestos en relación presentan incongruencia, obstáculos, desconocimiento o discrepancia y que constituyen el objeto de estudio.
V Fundamentación teórica	La Fundamentación Teórica plantea la perspectiva desde donde se desarrollará el estudio (modelo teórico, básico), los elementos del tema que consideramos más significativos (variable con las cuales va a interactuar el investigador), y los instrumentos teóricos de análisis de los datos obtenidos.
VI Hipótesis y objetivos	La hipótesis es un enunciado a renglón corrido, que plantea una posible respuesta a la pregunta de investigación basada en la teoría y en la práctica, estableciendo relaciones entre las variables del problema y que al contrastarse proporcionará conocimiento nuevo en la disciplina de estudio.
(de acuerdo al tipo de programa)	Los objetivos son alcanzables, específicos, medibles, realistas y tienen un plazo. Existe congruencia entre el título de la tesis, la hipótesis y los objetivos.
VII Metodología y cronograma	La metodología describe los materiales, herramientas y métodos que se usarán para verificar la hipótesis y lograr los objetivos del trabajo de investigación, a un nivel de detalle suficiente para permitir la réplica del trabajo. El cronograma está desarrollado en un diagrama de Gantt y el proyecto se puede concluir dentro de los tiempos establecidos en el programa de posgrado correspondiente.
VIII Resultados esperados, posibles aplicaciones y uso del proyecto	Se especifican los productos del trabajo, su impacto científico, tecnológico y económico.
IX Referencias bibliográficas	Las referencias son recientes, pertinentes, están citadas en el texto y se apegan al formato que sugiere la Dirección de Investigación y Posgrado de la UAQ, o el Journal of Animal Science Style and Form (Revised 2005).
<b>Elementos Éticos del Protocolo</b>	<b>Requerimiento para ser Evaluado por el Comité de Ética para la Investigación</b>
1. Aspectos generales	¿Incluye el protocolo las aclaraciones respecto Anexo II del comité de ética: Formato de Registro ante el Comité de Ética para la Investigación de la Facultad de Ingeniería de la Universidad Autónoma de Querétaro?
2. Seguridad	¿Se incluye en el protocolo una sección sobre seguridad y buenas prácticas de laboratorio que garanticen la integridad de los investigadores y participantes involucrados?

Nombre: PEDRAZA ORTEGA JESUS CARLOS  
Puesto de sinodal: SECRETARIO  
Fecha: 28/02/2022 22:55



Nota: La obtención del voto aprobatorio se realiza por medio de la plataforma SAIP

Figura 12.2: Votos aprobatorios: co-director de tesis.



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO  
FACULTAD DE INGENIERÍA  
DIVISIÓN DE INVESTIGACIÓN Y POSGRADO

VOTOS APROBATORIOS  
DE PROTOCOLO DE TESIS

PROGRAMA DE ESTUDIOS: Maestría en Ciencias en Inteligencia Artificial  
 NOMBRE: LEYVA LOPEZ SHEILA  
 NOMBRE DE LA TESIS: Predicción del daño pulmonar ocasionado por fibrosis pulmonar idiopática mediante aprendizaje profundo en imágenes de tomografía computarizada de tórax

Elemento del protocolo	Requerimiento
Redacción y Estilo	El documento es legible, coherente y está libre de errores gramaticales. El estilo es directo, impersonal y se enfoca en las evidencias, análisis, hallazgos y resultados.
Formato	El documento se apega a la estructura y lineamientos del formato aprobado por la DIPFI.
- Título del proyecto de tesis	El título describe la esencia del trabajo en 20 palabras o menos.
- Línea de investigación	El trabajo se inserta en una de las Líneas de Generación y Aplicación del Conocimiento del programa de estudios correspondiente.
II Antecedentes	Los antecedentes describen la evaluación del conocimiento acerca del fenómeno o hecho a investigar. Se identifican el estado del arte y de la técnica relacionados con el problema bajo estudio.
III Justificación	Se aporta evidencia que demuestra la pertinencia del trabajo en el contexto de la(s) disciplina(s) del programa y la viabilidad económica y técnica del proyecto.
IV Descripción del problema	Se identifican los fenómenos, hechos o situaciones, que puestos en relación presentan incongruencia, obstáculos, desconocimiento o discrepancia y que constituyen el objeto de estudio.
V Fundamentación teórica	La Fundamentación Teórica plantea la perspectiva desde donde se desarrollará el estudio (modelo teórico, básico), los elementos del tema que consideramos más significativos (variable con las cuales va a interactuar el investigador), y los instrumentos teóricos de análisis de los datos obtenidos.
VI Hipótesis y objetivos (de acuerdo al tipo de programa)	La hipótesis es un enunciado a renglón corrido, que plantea una posible respuesta a la pregunta de investigación basada en la teoría y en la práctica, estableciendo relaciones entre las variables del problema y que al contrastarse proporcionará conocimiento nuevo en la disciplina de estudio. Los objetivos son alcanzables, específicos, medibles, realistas y tienen un plazo. Existe congruencia entre el título de la tesis, la hipótesis y los objetivos.
VII Metodología y cronograma	La metodología describe los materiales, herramientas y métodos que se usarán para verificar la hipótesis y lograr los objetivos del trabajo de investigación, a un nivel de detalle suficiente para permitir la réplica del trabajo. El cronograma está desarrollado en un diagrama de Gantt y el proyecto se puede concluir dentro de los tiempos establecidos en el programa de posgrado correspondiente.
VIII Resultados esperados, posibles aplicaciones y uso del proyecto	Se especifican los productos del trabajo, su impacto científico, tecnológico y económico.
IX Referencias bibliográficas	Las referencias son recientes, pertinentes, están citadas en el texto y se apegan al formato que sugiere la Dirección de Investigación y Posgrado de la UAQ, o el Journal of Animal Science Style and Form (Revised 2005).
<b>Elementos Éticos del Protocolo</b>	<b>Requerimiento para ser Evaluado por el Comité de Ética para la Investigación</b>
1.Aspectos generales	¿Incluye el protocolo las aclaraciones respecto Anexo II del comité de ética: Formato de Registro ante el Comité de Ética para la Investigación de la Facultad de Ingeniería de la Universidad Autónoma de Querétaro?
2.Seguridad	¿Se incluye en el protocolo una sección sobre seguridad y buenas prácticas de laboratorio que garanticen la integridad de los investigadores y participantes involucrados?

Nombre: TOVAR ARRIAGA SAUL  
 Puesto de sinodal: VOCAL  
 Fecha: 04/03/2022 14:12



Nota: La obtención del voto aprobatorio se realiza por medio de la plataforma SAIP

Figura 12.3: Votos aprobatorios: secretario.



C. U., 8 de junio de 2022

**Sheila Leyva López**  
**Estudiante de Maestría en Ciencias en Inteligencia Artificial**  
**Expediente 311375**

**Presente**

El Comité de Ética Aplicada para la Investigación de la Facultad de Ingeniería ha revisado el protocolo del trabajo de tesis:

CEAIFI-079-2022-TP

**Predicción del daño pulmonar ocasionado  
por fibrosis idiopática pulmonar mediante aprendizaje profundo  
en imágenes de tomografía computarizada de tórax**

Con apego a los lineamientos éticos de beneficencia, no maleficencia, justicia y autonomía, este comité ha dado el siguiente dictamen:

**Aprobado éticamente**

El presente dictamen tiene vigencia de un año a partir de su fecha de emisión.

Sirva esta carta para los fines académicos que al interesado convengan.

Atentamente  
**"El Ingenio para Crear, No para Destruir"**

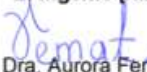
  
Dra. Aurora Femat Díaz  
Presidente del CEAIFI  
afemat@uaq.mx

Figura 12.4: Aprobación por comité de ética.





**DIPFI**  
POSGRADO  
INGENIERÍA

UNIVERSIDAD AUTÓNOMA DE QUERÉTARO  
FACULTAD DE INGENIERÍA  
DIVISION DE INVESTIGACIÓN Y POSGRADO

**REGISTRO DEL PROTOCOLO DE INVESTIGACIÓN  
DEL ESTUDIANTE DE POSGRADO**

Los 2 Espacios oscuros exclusivos para la Dirección	No. Registro de Proyecto*:	13302
	Fecha de Registro*:	16-06-2022
	Fecha de inicio de proyecto:	(17/01/2022)
	Fecha de término de proyecto:	(17/01/2024)
<b>1. DATOS DEL SOLICITANTE</b>		
No. de expediente:	311375	
Apellido Paterno	Apellido Materno	Nombre(s)
LEYVA	LOPEZ	SHEILA
Dirección:		
Calle y número	Colonia	
Montes #710	Villas de Santiago	
Estado	Teléfono (incluir lada)	
22	5520778700	
<b>2. DATOS DEL PROYECTO</b>		
Facultad:	<b>INGENIERÍA</b>	
Programa:	MAESTRIA EN CIENCIAS EN INTELIGENCIA ARTIFICIAL	
Tema específico del proyecto:	Predicción del daño pulmonar ocasionado por fibrosis pulmonar idiopática mediante aprendizaje profundo en imágenes de tomografía computarizada de tórax	
 SALAZAR COLORES SEBASTIÁN Director de tesis	 TOVARRRIAGA SAUL Coordinador de programa	 LEYVA LOPEZ SHEILA Alumno
Dr. Juan Carlos Jáuregui Correa Jefe de División de Investigación y Posgrado de la Fac. de Ing.	 Dr. Manuel Toledano Ayala Director de Fac. Ing.	 Dra. Ma. Guadalupe Flavia Loarca Piña Directora de Investigación y Posgrado UAQ

Anexo 3 Manual de procedimientos Administrativos de Posgrado de la Facultad de Ingeniería

Figura 12.5: Registro de protocolo.




**UNIVERSIDAD AUTÓNOMA DE QUERÉTARO**  
**FACULTAD DE LENGUAS Y LETRAS**



**A QUIEN CORRESPONDA:**

La que suscribe, Directora de la Facultad de Lenguas y Letras, hace **C O N S T A R** que

**LEYVA LÓPEZ SHEILA**

Presentó el **Examen de Manejo de la Lengua** efectuado el día diecisiete de junio de dos mil veintidós, en el cual obtuvo la siguiente calificación:

**9-**

Se extiende la presente a petición de la parte interesada, para los fines escolares y legales que le convengan, en el Campus Aeropuerto de la Universidad Autónoma de Querétaro, el día veintiocho de junio de dos mil veintidós.



Atentamente,  
"Enlazar Culturas por la Palabra"



**DRA. ADELINA VELÁZQUEZ HERRERA**



**AVH/japa\*CL\*FLL-C.-1235**

---

**SOMOS UAQ**  
SERVIR. CONSTRUIR. TRANSFORMAR.

Campus Aeropuerto, Anillo Vial Fray Junípero Serra S/N, Querétaro, Qro. C.P. 76140  
Tel. 442 192 12 00 Dirección Ext. 61010, Secretaría Administrativa Ext. 61300, Posgrado Ext. 61140,  
Licenciatura Ext. 61070, Centro de Lenguas Ext. 61050, Secretaría Académica Ext. 61100 y Planeación Ext. 61110

Figura 12.6: Constancia de manejo de la lengua inglés.




**UNIVERSIDAD AUTÓNOMA DE QUERÉTARO**  
**FACULTAD DE LENGUAS Y LETRAS**



**A QUIEN CORRESPONDA:**

La que suscribe, Directora de la Facultad de Lenguas y Letras, hace **C O N S T A R** que

**LEYVA LÓPEZ SHEILA**

Presentó y acreditó el **Examen de Comprensión de Textos en Inglés** efectuado el día seis de marzo de dos mil veintitrés.

Se extiende la presente a petición de la parte interesada, para los fines escolares y legales que le convengan, en el Campus Aeropuerto de la Universidad Autónoma de Querétaro, el día veintiocho de marzo de dos mil veintitrés.



Atentamente,  
"Enlazar Culturas por la Palabra"



**DRA. ADELINA VELÁZQUEZ HERRERA**



**AVH/daa\*CL\*FLL-C.-790**

---

**SOMOS UAQ**  
SERVIR CONSTRUIR TRANSFORMAR

Campus Aeropuerto, Anillo Vial Fray Junipero Serra S/N, Querétaro, Qro. C.P. 76140  
Tel. 442 192 12 00 Dirección Ext. 61010, Secretaría Administrativa Ext. 61300, Posgrado Ext. 61140,  
Licenciatura Ext. 61070, Centro de Lenguas Ext. 61050, Secretaría Académica Ext. 61100 y Planeación Ext. 61110

Figura 12.7: Constancia de comprensión de textos en inglés.

Diseño y Planeación Mecatrónica, Capítulo 19, pp. 262 - 271.  
 ISBN: 978-607-9394-25-7  
 Asociación Mexicana de Mecatrónica A.C., 2022



## Aprendizaje Automático para la Detección del Daño Pulmonar a través de Parámetros Clínicos

Leyva López Sheila<sup>1</sup>, <sup>✉</sup>Salazar Colores Sebastián<sup>2</sup>, Hernández Nava Gerardo<sup>1</sup> y Pedraza Ortega Jesús-Carlos<sup>1</sup>.

<sup>1</sup> Universidad Autónoma de Querétaro, Facultad de Ingeniería, Querétaro, Querétaro, México.

<sup>2</sup> Centro de Investigaciones en Óptica, León, Guanajuato, México.  
<sup>✉</sup>sebastian.salazar@cio.mx

### Resumen

*El aprendizaje automático es un campo de la inteligencia artificial especializado en la tarea de clasificación a partir de patrones extraídos de datos. En los últimos años sus aplicaciones en medicina han tenido un éxito sin precedentes. Enfermedades como la fibrosis pulmonar idiopática requieren un correcto diagnóstico temprano para favorecer la calidad de vida del paciente. Esta enfermedad ha sido diagnosticada mayormente desde el enfoque de visión artificial. Sin embargo, no siempre es posible proveer imágenes médicas a estos sistemas de visión. En esta investigación se presentan los resultados de realizar una exploración en la tarea de clasificación del daño pulmonar sobre únicamente parámetros clínicos: edad y sexo del paciente, su relación con el tabaco, y el resultado de su capacidad vital forzada. Tres populares paradigmas de inteligencia artificial fueron desarrollados y analizados: una red neuronal artificial, bosques aleatorios, y regresión logística. Bajo las métricas de exactitud, sensibilidad y puntaje-F1 se muestra que bosques aleatorios obtuvo el puntaje más alto para esta tarea con 92%, 93% y 94%, respectivamente.*

**Palabras clave:** Fibrosis Pulmonar, Capacidad Vital Forzada, Redes Neuronales Artificiales, Árboles Aleatorios, Regresión Logística.

Figura 12.8: Artículo publicado en el congreso MECAMEX como primer autor.



Diseño y Planeación Mecatrónica, Capítulo 3, pp. 27 - 38.  
 ISBN: 978-607-9394-25-7  
 Asociación Mexicana de Mecatrónica A.C., 2022



## Ictal-net: un Diseño de CNN para la Clasificación de Escalogramas de Electroencefalogramas con Crisis Convulsivas

Hernández Nava Gerardo, Salazar Colores Sebastián, Ortiz Echeverri César Javier,  
 Leyva López Sheila y Ramos-Arreguín Juan Manuel<sup>✉</sup>

Universidad Autónoma de Querétaro, Facultad de Ingeniería  
<sup>✉</sup>juan.ramos@uaq.mx

### Resumen

*La epilepsia es una enfermedad neurológica caracterizada por convulsiones de manera recurrente y aleatoria, que afecta a alrededor de 70 millones de personas en todo el mundo. Actualmente, en la epileptología, área que trata con la clasificación, detección y predicción de eventos epilépticos, se ha trabajado con la aplicación de técnicas de inteligencia artificial, como el aprendizaje profundo. Sin embargo, en tareas como la clasificación aún existe un margen de mejora en términos de exactitud, precisión, sensibilidad y puntaje F1. Por ello en este trabajo se presenta Ictal-net, una red neuronal convolucional propuesta para la clasificación periodos ictales (estados convulsivos) e interictales (estados libres de convulsiones) en señales de electroencefalografía. El objetivo de la red propuesta es detectar ataques epilépticos, para lo cual fueron caracterizadas señales de EEG mediante escalogramas obtenidos de la transformada wavelet continua. En este trabajo se utilizaron registros provenientes de la Universidad de Bonn, Alemania. Ictal-net obtuvo un 93.9% de exactitud, 95.47% en precisión, sensibilidad del 92.19% y un puntaje F1 de 93.8%, cifras que se encuentran entre las mejores reportadas en la literatura.*

**Palabras clave:** Epilepsia, Clasificación, Escalogramas, Electroencefalograma, Transformada Wavelet Continua, Red Neuronal Convolutacional.

Figura 12.9: Artículo publicado en el congreso MECAMEX como tercer autor.

Figura 12.10: Aportación social: plantilla en formato látex para protocolo de tesis.

The screenshot shows the Microsoft Learn interface for the 'Mes de Datos' challenge. The top navigation bar includes 'Microsoft Learn', 'Documentación', 'Cursos', 'Certificaciones', 'Q&A', 'Ejemplos de código', 'Valoraciones', 'Programa', and 'Eventos'. A search bar and a 'GH' icon are on the right. Below the navigation, there are links for 'Cursos', 'Productos', 'Rutas profesionales', 'Rutas de aprendizaje', 'Cursos', 'Centro para formadores', 'Centro de estudiantes', and 'Preguntas más frecuentes y ayuda'. A progress indicator shows 'NIVEL 7' and '6000/16199 XP'. The main content area features a purple background with a glowing circuit pattern and the text: 'DESAFÍO DE CONOCIMIENTOS DE LA NUBE', 'Mes de Datos', and a paragraph about the challenge. A 'Sumar' button is visible. Below this, a dark blue section displays 'Enhorabuena, ha conseguido el desafío.' and a progress bar for 'Módulos que ha completado' at '29 / 29'. To the right, a box shows the completion date '30 mar 2023' and a 'Ver la colección de desafíos' button. At the bottom, there is a notification preference link: '¿No recibe notificaciones? Actualice sus preferencias de correo electrónico en su perfil.'

Figura 12.11: Actividad extracurricular: Cloud Skills Challenge de Microsoft.



Figura 12.12: Reconocimiento por participación en el XX encuentro Participación de la Mujer en la Ciencia en Centro de Investigaciones en Óptica (CIO).



Figura 12.13: Plataforma web desarrollada presentada en el XX encuentro Participación de la Mujer en la Ciencia en el CIO.



### DESARROLLO DE UNA HERRAMIENTA DE DIAGNÓSTICO TEMPRANO DE DAÑO PULMONAR BASADA EN APRENDIZAJE AUTOMÁTICO

Sheila Leyva-López<sup>1</sup>, Enrique Mena-Camilo<sup>1</sup>, Gerardo Hernández-Nava<sup>1</sup>, Sebastián Salazar-Colores<sup>2</sup>

<sup>1</sup>Universidad Autónoma de Querétaro, <sup>2</sup>Centro de Investigaciones en Óptica.  
sheileyva29@gmail.com

#### RESUMEN

El objetivo de este estudio ha sido desarrollar una plataforma interactiva basada en técnicas de aprendizaje automático para la predicción de daño pulmonar. Se utilizaron parámetros clínicos de 178 pacientes, incluyendo información sobre su edad, sexo, capacidad vital forzada y su historial de tabaquismo. Se ha utilizado el algoritmo de bosques aleatorios para entrenar el modelo y se ha evaluado su rendimiento mediante métricas de exactitud, precisión, sensibilidad y puntaje F1. La plataforma interactiva ha sido desarrollada para permitir que los usuarios introduzcan los parámetros clínicos relevantes y obtengan una clasificación de si tienen o no daño pulmonar. Esta plataforma resulta ser de fácil uso y permite la interacción con los datos de manera visual e intuitiva. El modelo de predicción, que se ha entrenado utilizando el algoritmo de bosques aleatorios, ha demostrado un alto rendimiento en la identificación de daño pulmonar, obteniendo una exactitud del 90% y el resto de las métricas (precisión, sensibilidad y puntaje F1) con 92%. El desarrollo de esta plataforma interactiva basada en técnicas de aprendizaje automático y datos clínicos relevantes representa una herramienta prometedora para el diagnóstico temprano de daño pulmonar en pacientes. La inclusión de los parámetros clínicos relevantes ha permitido una evaluación precisa y personalizada del riesgo de daño pulmonar.

#### INTRODUCCIÓN

La fibrosis pulmonar idiopática (FPI) es una enfermedad crónica y progresiva que afecta gravemente la salud. Su principal manifestación es una tos persistente que se desarrolla a lo largo de varios meses y, en la mayoría de los casos, se presenta después de un episodio respiratorio agudo [1]. Lamentablemente, hasta la fecha, no existe una cura para esta enfermedad. No obstante, es crucial contar con un diagnóstico preciso que pueda reducir el riesgo de mortalidad del paciente y, al mismo tiempo, mejorar su esperanza y calidad de vida. Cabe destacar que el promedio de supervivencia después de la aparición de los primeros síntomas varía entre 3 y 5 años.

La evaluación de la función pulmonar (PFP) es una prueba utilizada en la detección de la FPI. Esta prueba permite evaluar el correcto funcionamiento de los pulmones, determinando si la inspiración y la expiración del aire se están llevando a cabo de manera adecuada [2]. Se realizan varios exámenes dentro de esta evaluación, como la espirometría, las pruebas de volumen pulmonar, la oximetría, el análisis de la fracción de óxido nítrico espirado y las pruebas de gases en sangre arterial [3], [4].

La espirometría es una de las pruebas de función pulmonar más reconocidas y estandarizadas. Esta prueba permite detectar posibles obstrucciones en el flujo respiratorio mediante la medición precisa de los flujos y volúmenes de aire inhalado y exhalado. Se toman en cuenta dos parámetros fisiológicos fundamentales en la espirometría: el volumen espiratorio forzado en el primer segundo (FEV1) y la capacidad vital forzada (CVF). La CVF se refiere al volumen máximo de aire exhalado de manera forzada por la boca después de una inhalación profunda [5]. Se considera que la CVF es normal cuando supera el 80% de su valor teórico [6]. Sin embargo, en pacientes con fibrosis pulmonar idiopática, suele disminuir.

Figura 12.14: Trabajo en extenso entregado en el XX encuentro Participación de la Mujer en la Ciencia en el CIO.

# Improving Idiopathic Pulmonary Fibrosis Damage Prediction with Segmented Images in a Deep Learning Model

1<sup>st</sup> Sheila Leyva-López  
Faculty of Engineering  
Autonomous University of Queretaro  
Queretaro, Mexico  
0000-0003-3634-8351

2<sup>nd</sup> Gerardo Hernández-Nava  
Faculty of Engineering  
Autonomous University of Queretaro  
Queretaro, Mexico  
0000-0002-8685-1003

3<sup>rd</sup> Enrique Mena-Camilo  
Faculty of Engineering  
Autonomous University of Queretaro  
Queretaro, Mexico  
0000-0001-8353-9017

4<sup>th</sup> Sebastián Salazar-Colores  
Centro de Investigaciones en Óptica  
León, México  
0000-0002-6353-0864

**Abstract**—This work introduces a semantic segmentation model, UNet, as a preprocessing module to an algorithm predicting lung damage caused by Idiopathic Pulmonary Fibrosis. By modifying the model input through the incorporation of a guide image (a segmentation result) into the original image, we observed an improved performance of eight out of twelve tested backbones in the prediction model, with an improvement of up to 0.57 in the  $LLL_m$  metric. This study underscores the significance of data preprocessing in deep learning models' performance. The inclusion of additional data, such as segmented images, can significantly enhance a model's ability to perform specific tasks, emphasizing the need for careful data preprocessing to obtain precise and reliable results when implementing deep learning models for lung damage prediction.

**Index Terms**—Segmentation, Deep Learning, Idiopathic Pulmonary Fibrosis, Computed Tomography.

## I. INTRODUCTION

Idiopathic Pulmonary Fibrosis (IPF) is a chronic, progressive, and debilitating disease that is primarily characterized by persistent coughing that evolves over several months, often preceded by an acute respiratory illness [1]. To date, IPF remains an incurable disease. However, an accurate and timely diagnosis can significantly contribute to reducing the mortality associated with this pathology and improving the life expectancy and quality of life of affected patients. It is worth noting that, after the onset of the first symptoms, the average survival interval ranges between 2 and 5 years [1] [2].

The main objective of this work is to improve the prediction of lung damage caused by IPF by implementing a UNet semantic segmentation module. This is a preprocessing block for the network proposed in [3], which is an end-to-end multimodal learning-based approach that predicts the decline of forced vital capacity (FVC) in patients with IPF, using Computed Tomography (CT) images and demographic information in convolutional neural network (CNN) frameworks with a stacked attention layer.

To evaluate the models, two main metrics are considered, Laplace Log-Likelihood ( $LLL_m$ ) (Equation 1), which measures a model's ability to correctly predict the classes or values of a test dataset, using logarithmic probability as a measure of error. One advantage of this metric is that it avoids problems of overfitting and underestimating the model's accuracy. Moreover, it is especially useful when working with small or imbalanced datasets [4]. The root mean squared error ( $RMSE$ ) (Equation 2) is also used, which evaluates the accuracy of a regression model.  $RMSE$  measures the average squared difference between the actual values and the predicted values by the model [5].

$$LLL_m = \log\left(P + \frac{1}{N + K}\right) \quad (1)$$

where:

$LLL_m$  is the Laplace Log-Likelihood.  $P$  stands for the number of correct predictions made by the model on the test dataset.  $N$  is the size of the test dataset.  $K$  is the number of classes or possible values.

$$RMSE = \sqrt{\frac{\sum (y - y_{pred})^2}{n}} \quad (2)$$

where:

$n$  represents the number of observations in the dataset.  $y$  is the true value of the response variable.  $y_{pred}$  is the predicted value of the response variable.

## II. DATABASE

The database provided in [6] comprises 176 training subjects and 5 test subjects. However, for this study, we decided to only utilize the training set as the remaining subjects are unlabeled. The segmentation of this training set is described in the methodology section. The main objective is to predict the last three forced vital capacity (FVC) measurements, as well

Figura 12.15: Artículo presentado en el 2023 IEEE Conference on Artificial Intelligence (CAI) en Santa Clara, California, USA. En Junio 5 y 6 del año 2023.

The image shows a screenshot of the IEEE Xplore website. At the top, there is a dark blue navigation bar with the IEEE Xplore logo on the left, and links for 'Browse', 'My Settings', and 'Help' in the center. On the right side of the navigation bar is a blue button labeled 'Institutional Sign In'. Below the navigation bar is a search bar with a dropdown menu set to 'All' and a search icon on the right. The main content area has a breadcrumb trail: 'Conferences > 2023 IEEE Conference on Artif...'. The article title is 'Improving Idiopathic Pulmonary Fibrosis Damage Prediction with Segmented Images in a Deep Learning Model'. Below the title, it says 'Publisher: IEEE' and has buttons for 'Cite This' and 'PDF'. The authors listed are 'Sheila Leyva-López ; Gerardo Hernández-Nava ; Enrique Mena-Camilo ; Sebastián Salazar-Colores' followed by a link for 'All Authors'. There are icons for 'Reprints', 'Share', 'Copyright', 'Folder', and 'Notification'. On the left side, there is a 'Document Sections' table of contents with 'Abstract' selected.

IEEE Xplore® Browse ▾ My Settings ▾ Help ▾ Institutional Sign In

All

ADVANCED SEARCH

Conferences > 2023 IEEE Conference on Artif... ?

## Improving Idiopathic Pulmonary Fibrosis Damage Prediction with Segmented Images in a Deep Learning Model

Publisher: IEEE Cite This PDF

Sheila Leyva-López ; Gerardo Hernández-Nava ; Enrique Mena-Camilo ; Sebastián Salazar-Colores All Authors

Reprints Share Copyright Folder Notification

Abstract	Abstract:
Document Sections	This work introduces a semantic segmentation model, UNet, as a preprocessing module to an algorithm predicting lung damage caused by Idiopathic Pulmonary Fibrosis. By modifying the model input through the incorporation of a guide image (a segmentation result) into the original image, we observed an improved performance of eight out of twelve tested backbones in the prediction model, with an improvement of up to 0.57 in the LLL m metric. This study underscores the significance of data preprocessing in deep learning models' performance. The inclusion of
I. Introduction	
II. Database	
III. Methodology	

Figura 12.16: Artículo presentado en CAI, ahora en la plataforma IEEE Xplore.



Figura 12.17: Asistencia al AI CODE FEST TECH N' FEST llevado a cabo por Globant, en la ciudad de Guadalajara, México, el 10 de junio del 2023.

## Microsoft Learn Student Ambassadors | 2023

This certificate is presented to:

SHEILA

LEYVA

Student Ambassador

In recognition of your hard work and dedication as  
a member of the Student Ambassadors team.



Pablo Veramendi  
Global Director | Microsoft Learn Student Ambassadors



Figura 12.18: Incorporación a la comunidad de Microsoft Learn Student Ambassadors.





Figura 12.19: Curso oficial: AZ-900T00-A-Microsoft Azure Fundamentals.