



**EDUCACIÓN**

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO  
NACIONAL DE MÉXICO

# Tecnológico Nacional de México

**Centro Nacional de Investigación  
y Desarrollo Tecnológico**

## Tesis de Maestría

**Detección de COVID-19 y otras enfermedades  
respiratorias analizando radiografías torácicas**

presentada por

**Ing. Emanuel Reyes Sánchez**

como requisito para la obtención del grado de  
**Maestro en Ciencias de la Computación**

Director de tesis

**Dr. Nimrod González Franco**

Codirector de tesis

**Dr. Dante Mújica Vargas**

**Cuernavaca, Morelos, México. 20 de Febrero de 2025.**



Cuernavaca, Mor., 31/enero/2025

OFICIO No. DCC/038/2025

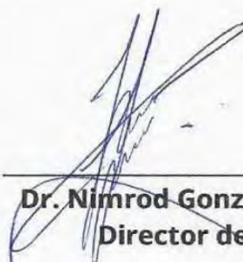
Asunto: Aceptación de documento de tesis  
CENIDET-AC-004-M14-OFICIO

**CARLOS MANUEL ASTORGA ZARAGOZA**  
**SUBDIRECTOR ACADÉMICO**  
**PRESENTE**

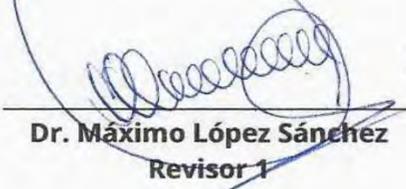
Por este conducto, los integrantes de Comité Tutorial de **Emanuel Reyes Sánchez** con número de control **M21CE025**, de la Maestría en Ciencias de la Computación, le informamos que hemos revisado el trabajo de tesis de grado titulado **"Detección de COVID-19 y otras enfermedades respiratorias analizando radiografías torácicas"** y hemos encontrado que se han atendido todas las observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.

**ATENTAMENTE**

*Excelencia en Educación Tecnológica®*  
*"Conocimiento y Tecnología al Servicio de México"*

  
\_\_\_\_\_  
**Dr. Nimrod González Franco**  
Director de tesis

  
\_\_\_\_\_  
**Dr. Dante Mújica Vargas**  
Codirector de tesis

  
\_\_\_\_\_  
**Dr. Máximo López Sánchez**  
Revisor 1

  
\_\_\_\_\_  
**Dra. Andrea Magadán Salazar**  
Revisor 2

  
\_\_\_\_\_  
**Dr. Raúl Pinto Elías**  
Revisor 3

C.c.p.      Depto. Servicios Escolares.



**2025**  
Año de  
**La Mujer Indígena**

Interior Internado Palmira S/N, Col. Palmira,  
C. P. 62490, Cuernavaca, Morelos Tel. 01 (777) 3627770, ext. 3201,  
e-mail: dcc\_cenidet@tecnm.mx tecnm.mx | cenidet.tecnm.mx





Cuernavaca Mor, **13/febrero/2025**

Oficio No. SAC/061/2025

Asunto: Autorización de impresión de tesis

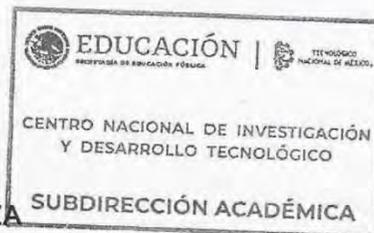
**EMANUEL REYES SÁNCHEZ**  
**CANDIDATO AL GRADO DE MAESTRO**  
**EN CIENCIAS DE LA COMPUTACIÓN**  
**P R E S E N T E**

Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado "Detección de COVID-19 y otras enfermedades respiratorias analizando radiografías torácicas", ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.

Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

**A T E N T A M E N T E**

*Excelencia en Educación Tecnológica@*  
*"Conocimiento y Tecnología al Servicio de México"*



**CARLOS MANUEL ASTORGA ZARAGOZA**  
**SUBDIRECTOR ACADÉMICO**

c.c.p. Departamento de Ciencias Computacionales  
Departamento de Servicios Escolares

CMAZ/lmz



**2025**  
Año de  
**La Mujer Indígena**



# Dedicatoria

A Dios

Por brindarme bendiciones constantes a lo largo de mi vida.

A mi madre

***María Marleni Sánchez***

Por estar siempre a mi lado cuando más la necesite.

A mi padre

***Victor Manuel Reyes***

Por todos los consejos brindados.

A mis hermanos

***Victor y Guadalupe***

Por ser los mejores compañeros de vida.

A mi pareja

***Itzel Martínez***

Por estar a mi lado en la adversidad.

## **Agradecimientos**

Agradezco al Secretaría de Ciencias, Humanidades, Tecnología e Innovación (SECIHTI) por la beca otorgada durante mis estudios de maestría en Ciencias de la Computación.

Al Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET) por haberme permitido realizar los estudios de una Maestría en Ciencias en tan prestigiosa Institución.

De forma especial agradezco a mi director de tesis Dr. Nimrod González Franco, por su apoyo y guía brindada durante el desarrollo de este trabajo de tesis. A mi codirector Dr. Dante Mújica Vargas, por sus sugerencias durante el desarrollo de esta tesis. Al comité revisor, Dr. Raúl Pinto Elías, Dr. Máximo López Sánchez y a la Dra. Andrea Magádan Salazar, por su tiempo para la revisión de esta investigación, acompañada de comentarios y sugerencias para el mejoramiento de este trabajo de tesis.

# Resumen

En este trabajo se presenta el desarrollo de un modelo de aprendizaje profundo implementando una Red Neuronal Convolutiva en conjunto con diferentes técnicas de preprocesamiento; que permite clasificar imágenes de radiografía de tórax en dos clases, siendo estas COVID-19 y NOCOVID-19. En este trabajo de investigación se establecieron 4 módulos: Adquisición y selección de conjuntos de imágenes médicas; Desarrollo del repositorio de radiografías de tórax; Análisis y selección de técnicas de preprocesamiento; y, Análisis y selección de técnicas de clasificación.

En adquisición y selección de conjuntos de imágenes médicas, se realizó la recopilación de un gran conjunto de radiografías de tórax de pacientes con COVID-19, neumonías viral y bacteriana, y NOCOVID-19 (otras afectaciones pulmonares); se utilizaron 10 conjuntos de imágenes de acceso público provenientes de instituciones médicas, universidades, hospitales y médicos de diversas partes del mundo. El desarrollo del repositorio de radiografías de tórax consistió en que, tras la adquisición de imágenes, se realizó un cribado para descartar imágenes repetidas o de baja calidad, conformando una cantidad de radiografías de 6,050 de COVID-19, 2,630 de Neumonía Viral, 2,467 de Neumonía Bacteriana y 10,969 de NOCOVID-19. En Análisis y selección de técnicas de preprocesamiento, se realizó la normalización del conjunto de datos, Análisis e implementación de las técnicas de filtrado HE, BCET, CLAHE, Corrección Gamma y NCLAHE; Aumento del conjunto de datos mediante la reducción del ruido Impulsivo y Gaussiano, y descartar objetos presentes en algunas imágenes; destacando el conjunto de datos normalizados y aumentado, y aplicada la técnica de filtrado CLAHE. Análisis y selección de técnicas de clasificación, se evaluaron los modelos de Redes neuronales Convolutivas VGG-16, VGG-19, Xception, MobileNetV1, MobileNetV2 y ResNet50; en donde se seleccionó como modelo base a la RNC VGG-16.

El modelo propuesto se evaluó con las métricas de clasificación de Redes Neuronales Convolutivas de Exactitud, Sensibilidad, Precisión y Valor-F1. Obteniendo un rendimiento efectivo del 92.34% en exactitud al clasificar a las radiografías de tórax como COVID-19 y NOCOVID-19.

**Palabras Clave:** COVID-19, Redes Neuronales Convolutivas, Radiografía de Tórax, Aprendizaje Profundo, y Preprocesamiento.

## Abstract

This work presents the development of a deep learning model by implementing a Convolutional Neural Network along with various preprocessing techniques, enabling the classification of chest X-ray images into two categories: COVID-19 and NOCOVID-19. This research study established four modules: Acquisition and selection of medical image datasets; Development of the chest X-ray repository; Analysis and selection of preprocessing techniques; and, Analysis and selection of classification techniques.

In the acquisition and selection of medical image datasets, a large set of chest X-rays was collected from patients with COVID-19, viral and bacterial pneumonia, and NOCOVID-19 (other pulmonary conditions). Ten publicly accessible image datasets from medical institutions, universities, hospitals, and physicians worldwide were used. The development of the chest X-ray repository involved screening the acquired images to discard duplicates or low-quality images, resulting in a dataset comprising 6,050 COVID-19 X-rays, 2,630 Viral Pneumonia X-rays, 2,467 Bacterial Pneumonia X-rays, and 10,969 NOCOVID-19 X-rays. In the analysis and selection of preprocessing techniques, dataset normalization was performed, along with the analysis and implementation of filtering techniques such as HE, BCET, CLAHE, Gamma Correction, and NCLAHE. Additionally, data augmentation was carried out by reducing Impulsive and Gaussian noise and removing unwanted objects present in some images. The final dataset was both normalized and augmented, with the CLAHE filtering technique applied. For the analysis and selection of classification techniques, different Convolutional Neural Network models were evaluated, including VGG-16, VGG-19, Xception, MobileNetV1, MobileNetV2, and ResNet50. The VGG-16 CNN was selected as the base model.

The proposed model was evaluated using classification metrics for Convolutional Neural Networks, including Accuracy, Sensitivity, Precision, and F1-Score. The model achieved an effective performance of 92.34% accuracy in classifying chest X-rays as COVID-19 or NOCOVID-19.

**Keywords:** COVID-19, Convolutional Neural Networks, Chest X-ray, Deep Learning, and Preprocessing.

# Índice General

<b>RESUMEN</b> .....	<b>I</b>
<b>ABSTRACT</b> .....	<b>II</b>
<b>ACRÓNIMOS</b> .....	<b>XIII</b>
<b>CAPÍTULO 1</b> .....	<b>1</b>
<b>INTRODUCCIÓN</b> .....	<b>1</b>
1.1 DESCRIPCIÓN DEL PROBLEMA .....	2
1.1.1 Delimitación del problema específico .....	3
1.1.2 Complejidad del problema .....	3
1.2 OBJETIVOS .....	4
1.2.1 Objetivo General.....	4
1.2.2 Objetivos Específicos.....	4
1.3 ALCANCES Y LIMITACIONES .....	4
1.3.1 Alcances.....	4
1.3.2 Limitaciones.....	5
1.4 JUSTIFICACIÓN Y BENEFICIOS .....	5
1.5 ORGANIZACIÓN DE LA TESIS .....	6
<b>CAPÍTULO 2</b> .....	<b>7</b>
<b>MARCO CONCEPTUAL</b> .....	<b>7</b>
2.1 COVID-19.....	7
2.2 RADIOGRAFÍAS DE TÓRAX .....	8
2.3 ANORMALIDADES PRESENTES EN RADIOGRAFÍAS DE TÓRAX PARA DETERMINAR EL PREDIAGNÓSTICO DE COVID-19 .....	8
2.3.1 Hallazgos típicos asociados a la patología COVID-19 .....	9
2.3.2 Hallazgos no determinantes para el diagnóstico de COVID-19 .....	9
2.4 CONCEPTOS SOBRE LA CALIDAD VISUAL EN IMÁGENES MÉDICAS DE RADIOGRAFÍA .....	11

---

2.4.1 Contraste radiográfico .....	11
2.4.2 Subexposición y sobreexposición radiográfica.....	11
2.5 APRENDIZAJE PROFUNDO.....	11
2.6 REDES NEURONALES CONVOLUCIONALES .....	12
2.6.1 Arquitectura de las redes neuronales convolucionales .....	13
2.6.2 Redes Neuronales Convolucionales implementadas .....	16
2.7 CONCEPTOS BÁSICOS PARA LA IMPLEMENTACIÓN DE MODELOS DE APRENDIZAJE PROFUNDO .....	21
2.7.1 Hiperparámetros .....	21
2.7.2 Optimizador de aprendizaje Adadelta.....	21
2.7.3 Transferencia de Aprendizaje.....	21
2.7.4 Ajuste fino.....	22
2.7.5 Freezing.....	22
2.7.6 Aumento de datos.....	22
2.8 MÉTRICAS DE EVALUACIÓN DE LOS MODELOS DE APRENDIZAJE PROFUNDO .....	22
2.8.1 Exactitud .....	22
2.8.2 Precisión.....	23
2.8.3 Sensibilidad.....	23
2.8.4 Valor-F1.....	23
2.8.5 Matriz de confusión .....	23
<b>CAPÍTULO 3.....</b>	<b>25</b>
<b>ESTADO DEL ARTE .....</b>	<b>25</b>
3.1 ANTECEDENTES .....	25
3.2 TRABAJOS RELACIONADOS .....	25
3.2.1 Implementación de diferentes técnicas de preprocesamiento.....	26
3.2.2 Arquitectura de red neuronal convolucional.....	34
<b>CAPÍTULO 4.....</b>	<b>46</b>
<b>PROPUESTA DE SOLUCIÓN .....</b>	<b>46</b>
4.1 ADQUISICIÓN Y SELECCIÓN DE CONJUNTOS DE IMÁGENES MÉDICAS .....	46

---

4.2 DESARROLLO DEL REPOSITORIO DE RADIOGRAFÍAS DE TÓRAX .....	48
4.2.1 Selección de conjuntos de imágenes médicas .....	48
4.3 ANÁLISIS Y SELECCIÓN DE TÉCNICAS DE PREPROCESAMIENTO .....	50
4.3.1 Normalización del conjunto de datos .....	50
4.3.2 Análisis e implementación de técnicas de filtrado .....	51
4.3.3 Aumento del conjunto de datos .....	57
4.4 ANÁLISIS Y SELECCIÓN DE TÉCNICAS DE CLASIFICACIÓN .....	59
4.4.1 Implementación de una red neuronal convolucional para la clasificación de radiografía de tórax.....	59
4.4.2 Modelo de Red Neuronal Convolucional Propuesto .....	60
<b>CAPÍTULO 5.....</b>	<b>63</b>
<b>EXPERIMENTACIÓN Y PRUEBAS.....</b>	<b>63</b>
5.1 REPORTE DE EXPERIMENTACIÓN.....	63
5.1.1 Entorno de desarrollo .....	63
5.1.2 Parámetros base establecidos .....	64
5.1.3 Base de datos.....	65
5.1.4 Métricas.....	66
5.2 EXPERIMENTOS DESARROLLADOS.....	66
5.2.1 Experimentación implementando el conjunto de datos en crudo y técnica de <i>Freezing</i> .....	66
5.2.2 Experimentación de Redes Neuronales Convolucionales con datos en crudo y normalizados.....	67
5.2.3 Experimentaciones implementando el conjunto de datos normalizados con técnicas de preprocesamiento de filtrado y RNC VGG-16 .....	73
5.2.4 Experimento con un mayor conjunto de datos en crudo y entrenamiento.....	77
5.2.5 Experimentos con datos en crudo aplicando técnicas de filtrado .....	80
5.2.6 Sintonización de la técnica de Filtrado CLAHE del modelo VGG-16 ...	85

---

5.2.7 Sintonización de hiperparámetros del modelo de Red Neuronal Convolutiva propuesto.....	88
5.3 INFORME DE PRUEBAS DE MODELO DE APRENDIZAJE PROPUESTO.....	96
5.4 DISCUSIÓN .....	97
<b>CAPÍTULO 6.....</b>	<b>101</b>
<b>CONCLUSIONES Y TRABAJO FUTURO .....</b>	<b>101</b>
6.1 CONCLUSIONES.....	101
6.1.1 Objetivos y Alcances Logrados .....	101
6.1.2 Resultados del Trabajo .....	103
6.2 TRABAJOS FUTUROS .....	107
<b>REFERENCIAS.....</b>	<b>108</b>
<b>ANEXO A.....</b>	<b>115</b>

## Lista de Figuras

<b>Figura 2. 1.</b> Virus del SARS-CoV-2 (CDC,2020). .....	7
<b>Figura 2. 2.</b> Hallazgos típicos de la patología COVID-19 (Martínez, et al., 2021).. .....	9
<b>Figura 2. 3.</b> Hallazgos atípicos de neumonía COVID-19 (Martínez, et al., 2021).. .....	10
<b>Figura 2. 4.</b> Radiografía de tórax PA y lateral (Martínez, et al., 2021).. .....	10
<b>Figura 2. 5.</b> Ejemplos de radiografías de tórax que presentan (A) Subexposición, (B) Exposición correcta y (C) Sobreexposición. (Seibert & Morin, 2011).. .....	11
<b>Figura 2. 6.</b> Representación gráfica general de aprendizaje profundo (Shyam, et al., 2021). .....	12
<b>Figura 2. 7.</b> Arquitectura básica de una Red Neuronal Convolutiva (Mathworks, 2018). .....	13
<b>Figura 2. 8.</b> Ilustración grafica de operaciones de la convolución (Goodfellow, et al., 2016). .....	14
<b>Figura 2. 9.</b> Representación esquemática de la operación de convolución (Goodfellow, et al., 2016).. .....	14
<b>Figura 2. 10.</b> Max pooling bidimensional, aplicando un filtro de 2×2. ....	15
<b>Figura 2. 11.</b> Arquitectura de la Red Neuronal Convolutiva ResNet (Burgal, 2018). .....	17
<b>Figura 2. 12.</b> Arquitectura de la Red Neuronal Convolutiva VGG-16 (Dey, 2018).. ..	18
<b>Figura 2. 13.</b> Arquitectura de la Red Neuronal Convolutiva VGG-19 (Dey, 2018).. ..	19
<b>Figura 2. 14.</b> Arquitectura de la Red Neuronal Convolutiva Xception (Chollet, 2017). .....	20
<b>Figura 2. 15.</b> Arquitectura de la Red Neuronal Convolutiva MobileNet (Westphal, Seitz, 2020).. .....	21
<b>Figura 3. 1.</b> InstaCovNet-19 Modelo apilado integrado (Gupta, et al., 2020).. .....	26
<b>Figura 3. 2.</b> Proceso propuesto funciona de la siguiente manera: entrada de las imágenes, etapa de preprocesamiento, seguida de la segmentación, introducen simultáneamente en múltiples modelos y clasificación por el meta-aprendizaje en una de las tres clases: COVID-19 (C), Normal (N) y Neumonía (P) (Singh., et al, 2021).. .....	27
<b>Figura 3. 3.</b> Arquitectura del sistema de diagnóstico basado en Bayes-SqueezeNet (Ucar., et al, 2020). .....	28
<b>Figura 3. 4.</b> Descripción general modelo propuesto (Keidar, et al., 2021). .....	29
<b>Figura 3. 5.</b> Flujo de trabajo de la estimación del mapa de características radiómicas (Hu, et al., 2021). .....	30
<b>Figura 3. 6.</b> Diagrama de bloques del modelo propuesto (Akter, et al., 2021). .....	30
<b>Figura 3. 7.</b> Modelo propuesto (Heidari, et al., 2020). .....	31
<b>Figura 3. 8.</b> Arquitectura del modelo propuesto (Ahamed, et al., 2021). .....	32
<b>Figura 3. 9.</b> Diagrama de bloques sistemático del método propuesto para identificar la presencia del virus COVID-19 implementando radiografías de tórax (Jain, et al., 2020). .....	33

<b>Figura 3. 10.</b> Diagrama de bloques de la metodología propuesta (Rahman., et al 2021).	34
<b>Figura 3. 11.</b> Diagrama de flujo de la metodología del sistema (Das., et al, 2021).	35
<b>Figura 3. 12.</b> Arquitectura del modelo propuesto COVIDetectioNet (Turkoglu, 2020).	36
<b>Figura 3. 13.</b> Arquitectura del modelo propuesto (Ozturk., et al 2020).	36
<b>Figura 3. 14.</b> Arquitectura del modelo propuesto (Rahimzadeh., et al 2020).	37
<b>Figura 3. 15.</b> Diagrama de bloques del modelo propuesto de clasificación (Ibrahim., et al 2021).	38
<b>Figura 3. 16.</b> Arquitectura del modelo que tiene como base la red VGG-16 (Abdar., et al 2020).	38
<b>Figura 4. 1.</b> Diagrama de bloques de la propuesta de solución.	46
<b>Figura 4. 2.</b> A) Presencia de etiqueta realizada por el médico, B) Objeto personal del paciente, C) Dispositivo médico, D) Márgenes anexados en la imagen.	50
<b>Figura 4. 3.</b> A) Presencia de etiqueta realizada por el dispositivo de captura. B) Misma imagen normalizada.	51
<b>Figura 4. 4.</b> Radiografía de tórax positivo a COVID-19, A) Original. B) Radiografía aplicado filtro HE.	52
<b>Figura 4. 5.</b> Radiografía de tórax positivo a COVID-19 A) Original. B) Radiografía aplicado filtro de BCET.	53
<b>Figura 4. 6.</b> Radiografía de tórax positivo a COVID-19 A) Original. B) Radiografía aplicado filtro CLAHE.	54
<b>Figura 4. 7.</b> Radiografía de tórax positivo a COVID-19 A) Original. B) Radiografía aplicado filtro de gamma.	55
<b>Figura 4. 8.</b> Radiografía de tórax de paciente con COVID-19 A) Original. B) Radiografía aplicado filtro NCLAHE.	56
<b>Figura 4. 9.</b> Radiografías excluidas por el proceso de normalización. A) Ruido Impulsivo, B) Ruido Gaussiano y C) Etiqueta compleja de editar.	57
<b>Figura 4. 10.</b> Radiografías después del aplicar el filtro de Difusión anisotrópica. A) Ruido Impulsivo, B) Ruido Gaussiano.	58
<b>Figura 4. 11.</b> Radiografía después de aplicar LaMa para eliminar la etiqueta realizada por el dispositivo de captura.	58
<b>Figura 5. 1.</b> Radiografía de tórax positivo a COVID-19, A) Crudo. B) HE, C) BCET, D) CLAHE, E) NCLAHE y F) Corrección Gamma.	65
<b>Figura 5. 2.</b> Desempeño del modelo con datos en crudo con dos tipos de dimensiones. A) Evaluación de la exactitud del modelo con conjunto EG. B) Pérdida obtenido con conjunto EG.C) Evaluación de la exactitud del modelo con conjunto RGB. D) Pérdida obtenido con conjunto RGB.	79

<b>Figura 5. 3.</b> Desempeño del modelo implementando el conjunto de imágenes en crudo con la técnica de filtrado de BCET en EG. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento. ....	80
<b>Figura 5. 4.</b> Desempeño del modelo implementando el conjunto de imágenes en crudo con la técnica de filtrado de BCET en RGB. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento. ....	81
<b>Figura 5. 5.</b> Desempeño del modelo implementando el conjunto de imágenes en crudo con la técnica de filtrado de CLAHE en EG. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento. ....	81
<b>Figura 5. 6.</b> Desempeño del modelo implementando el conjunto de imágenes en crudo con la técnica de filtrado de CLAHE en RGB. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento. ....	82
<b>Figura 5. 7.</b> Desempeño del modelo implementando el conjunto de imágenes en crudo con la técnica de filtrado de Gamma en EG. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento. ....	83
<b>Figura 5. 8.</b> Desempeño del modelo implementando el conjunto de imágenes en crudo con la técnica de filtrado de Gamma en RGB. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento. ....	83
<b>Figura 5. 9.</b> Desempeño del modelo implementando el conjunto de imágenes en crudo con la técnica de filtrado de NCLAHE en EG. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento. ....	84
<b>Figura 5. 10.</b> Desempeño del modelo implementando el conjunto de imágenes en crudo con la técnica de filtrado de NCLAHE en RGB. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento. ....	84
<b>Figura 5. 11.</b> Radiografía de tórax positivo a COVID-19 A) Imagen en crudo. B) Radiografía aplicando filtro CLAHE.....	86
<b>Figura 5. 12.</b> Desempeño del modelo implementando el conjunto con nueva distribución de las imágenes normalizado y aplicada la técnica de filtrado de CLAHE estándar. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenida durante el entrenamiento.....	86
<b>Figura 5. 13.</b> Desempeño del modelo implementando el conjunto de imágenes normalizado ampliado con la técnica de filtrado de CLAHE. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento. ....	90
<b>Figura 5. 14.</b> Desempeño del modelo implementando el conjunto de imágenes normalizado con la técnica de filtrado de CLAHE. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento....	90
<b>Figura 5. 15.</b> Desempeño del modelo implementando el conjunto de imágenes normalizado ampliado con la técnica de filtrado de CLAHE. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento. ....	91

---

<b>Figura 5. 16.</b> Desempeño del modelo implementando el conjunto de imágenes normalizado aplicado filtro CLAHE e implementa la técnica FLIP teniendo como tamaño de lote el de 32 y 128.....	92
<b>Figura 5. 17.</b> Desempeño del modelo implementando el aumento de datos con tamaño de lote de 128 imágenes. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento. ....	93
<b>Figura 5. 18.</b> Resultados obtenidos con datos en crudo y normalizado por los modelos de RNC.....	97
<b>Figura 5. 19.</b> Resultados obtenidos por VGG-16 con datos normalizados y técnicas de preprocesamiento. ....	98
<b>Figura A. 1.</b> Certificado de registro del conjunto COVID-TECNM. ....	115
<b>Figura A. 2.</b> Artículo de Congreso publicado en Academia Journals Celaya 2022.....	116
<b>Figura A. 3.</b> Reconocimiento por el Taller: Inteligencia Artificial en el Tecnológico de Monterrey: Campus Xochitepec. ....	117
<b>Figura A. 4.</b> Constancia por el Taller: Deep Learning: Clasificación y Delimitación durante el 12° Congreso Internacional de Computación 2022.....	118
<b>Figura A. 5.</b> Constancia por participación como miembro del Comité Evaluador del 12° Congreso Internacional de Computación 2022.....	119

## Lista de Tablas

<b>Tabla 2. 1.</b> Distribución de casos en matriz de confusión.....	24
<b>Tabla 3. 1.</b> Implementación de diferentes técnicas de preprocesamiento.....	37
<b>Tabla 3. 2.</b> Arquitectura de Red Neuronal Convolutiva .....	41
<b>Tabla 4. 1.</b> Conjuntos de imágenes de datos. ....	47
<b>Tabla 4. 2.</b> Selección de imágenes de los conjuntos de datos.....	49
<b>Tabla 4. 3.</b> Recopilación de radiografías de tórax por clases. ....	49
<b>Tabla 4. 4.</b> Conjunto de imágenes de radiografías de tórax normalizado. ....	51
<b>Tabla 4. 5.</b> Conjunto de imágenes aumentado. ....	59
<b>Tabla 5. 1.</b> Conjunto de datos recopilado en crudo. ....	65
<b>Tabla 5. 2.</b> Distribución del conjunto de entrenamiento con imágenes en crudo.....	66
<b>Tabla 5. 3.</b> Desempeño de los modelos implementado freezing.....	67
<b>Tabla 5. 4.</b> Conjunto de imágenes en crudo distribuido para entrenamiento. ....	68
<b>Tabla 5. 5.</b> Desempeño de los modelos implementados en conjuntos de imágenes en crudo.....	69
<b>Tabla 5. 6.</b> Conjunto de imágenes de radiografías de tórax en crudo.....	70
<b>Tabla 5. 7.</b> Desempeño de los modelos de aprendizaje profundo implementados en el experimento.....	71
<b>Tabla 5. 8.</b> Conjunto de imágenes de radiografías de tórax normalizado. ....	72
<b>Tabla 5. 9.</b> Desempeño de los modelos de aprendizaje profundo implementados en el experimento.....	72
<b>Tabla 5. 10.</b> Desempeño de los modelos de aprendizaje profundo implementados en el experimento.....	74
<b>Tabla 5. 11.</b> Desempeño de los modelos de aprendizaje profundo implementados en el experimento.....	74
<b>Tabla 5. 12.</b> Desempeño de los modelos de aprendizaje profundo implementados en el experimento.....	75
<b>Tabla 5. 13.</b> Desempeño de los modelos de aprendizaje profundo implementados en el experimento.....	76
<b>Tabla 5. 14.</b> Desempeño de los modelos de aprendizaje profundo implementados en el experimento.....	77
<b>Tabla 5. 15.</b> Conjunto de imágenes de radiografías de tórax en crudo. ....	77
<b>Tabla 5. 16.</b> Evaluación del modelo VGG-16 con el conjunto de imágenes en crudo en EG y RGB.....	79
<b>Tabla 5. 17.</b> Evaluación del modelo VGG-16 con el conjunto de imágenes en crudo en EG y RGB implementando la técnica de filtrado BCET.....	81
<b>Tabla 5. 18.</b> Evaluación del modelo VGG-16 con el conjunto de imágenes en crudo implementando la técnica de filtrado CLAHE en EG y RGB.....	82
<b>Tabla 5. 19.</b> Evaluación del modelo VGG-16 con el conjunto de imágenes en crudo implementando la técnica de filtrado Gamma en EG y RGB.....	83

---

<b>Tabla 5. 20.</b> Evaluación del modelo VGG-16 con el conjunto de imágenes en crudo implementando la técnica de filtrado NCLAHE en EG y RGB.....	84
<b>Tabla 5. 21.</b> Aumento del conjunto de imágenes de radiografías de tórax normalizado.....	85
<b>Tabla 5. 22.</b> Evaluación del modelo VGG-16 con el conjunto normalizado implementando Filtrado la CLAHE.....	86
<b>Tabla 5. 23.</b> Sintonización del modelo VGG-16 con el conjunto de imágenes normalizado ampliado con filtrado CLAHE.....	87
<b>Tabla 5. 24.</b> Sintonización del modelo VGG-16 con el conjunto de imágenes normalizado ampliado con filtrado CLAHE (continuación).....	88
<b>Tabla 5. 25.</b> Sintonización del hiperparámetro del optimizador del modelo VGG-16 con el conjunto de imágenes normalizado nuevo con filtrado CLAHE.....	89
<b>Tabla 5. 26.</b> Sintonización del hiperparámetros del modelo VGG-16 con el conjunto normalizado aplicando la técnica CLAHE utilizando 300 época de entrenamiento.....	90
<b>Tabla 5. 27.</b> Sintonización del hiperparámetro del modelo VGG-16 con el conjunto de imágenes normalizado ampliado con 100 época de entrenamiento.....	91
<b>Tabla 5. 28.</b> Sintonización del del modelo VGG-16 con el conjunto de imágenes normalizado ampliado con 150 época de entrenamiento.....	91
<b>Tabla 5. 29.</b> Modelo VGG-16 implementando la técnica de aumento de datos Flip.....	93
<b>Tabla 5. 30.</b> Modelo VGG-16 implementando un tamaño de lotes de 128 imágenes.....	93
<b>Tabla 5. 31.</b> Modelo VGG-16 implementando un tamaño de lotes de 128 imágenes y 200 épocas.....	94
<b>Tabla 5. 32.</b> Modelo VGG-16 implementando un tamaño de lotes de 128 imágenes y 512 neuronas.....	94
<b>Tabla 5. 33.</b> Conjunto de imágenes de radiografías de tórax normalizado y aplicado filtro CLAHE sintonizado.....	95
<b>Tabla 5. 34.</b> Experimento con modelo sintonizado y técnicas de preprocesamiento implementadas.....	96
<b>Tabla 5. 35.</b> Nuevo conjunto de imágenes de radiografías de tórax normalizado y aplicado filtro CLAHE sintonizado.....	96
<b>Tabla 5. 36.</b> Experimento con modelo sintonizado y técnicas de preprocesamiento implementadas.....	96
<b>Tabla 6. 1.</b> Objetivos realizados.....	101
<b>Tabla 6. 2.</b> Alcances realizados.....	102

# Acrónimos

RNC	Red Neuronal Convolutacional
CNN	Convolutional Neural Network
HE	Ecualización del Histograma (Histogram equalization)
BCET	Mejora de Contraste Equilibrado (Balance Contrast Enhancement Technique),
CLAHE	Ecualización Adaptativa del Histograma Limitada por el Contraste
NCLAHE	Normalización con Ecualización Adaptativa del Histograma Limitada por el Contraste
EG	Escala de Grises
RGB	Canales Rojo, Verde y Azul (Red, Green y Blue)
GPU	Unidad gráfica de procesamiento (Graphics Processor Unit)
CENIDET	Centro Nacional de Investigación y Desarrollo Tecnológico
TP	Verdadero Positivo ( <i>True Positive</i> )
TN	Verdadero Negativo (True Negative)
FN	Falso Negativo ( <i>False Negative</i> )
FP	Falso Positivo (False Positive)
PNG	Portable Network Graphics
OMS	Organización Mundial de la Salud
SVM	Máquina de Soporte Vectorial
RAM	Memoria de Acceso Aleatorio (Random Access Memory)
CUDA	Arquitectura Unificada de Dispositivos de Computo (Compute Unified Device Architecture)
ADAM	Adaptive Moment Estimation
SECIHTI	Secretaría de Ciencias, Humanidades, Tecnología e Innovación

# Capítulo 1

En este Capítulo se presentan los aspectos fundamentales que servirán de soporte para este trabajo de tesis: la descripción, delimitación y complejidad del problema, los objetivos, alcances y limitaciones, así como la justificación y organización de la tesis.

## Introducción

Existen diferentes pruebas de diagnóstico para COVID-19, siendo una de las más populares la prueba de reacción en cadena de polimerasa transcriptasa reversa (RT-PCR), la cual presenta sensibilidad del 60%-70% al 95-97%, pudiendo obtener diagnósticos de falsos negativos en etapas precoces del padecimiento de la enfermedad; la RT-PCR requiere de recursos médicos para su aplicación y para la obtención de resultados se debe esperar entre 24 a 72 horas. La importancia de evitar la propagación de la pandemia causada por la enfermedad COVID-19, así como la escasez de kits de pruebas, las deficiencias presentes en ellas y la escasez de personal médico ocasiona el requerimiento de métodos auxiliares para el diagnóstico que permitan que los enfermos sean atendidos rápidamente (Martínez, et al., 2021; Ozturk, et al., 2020; Gestoso, et al., 2021).

Debido a ello se han desarrollado diferentes métodos de aprendizaje automático para el diagnóstico de COVID-19 a partir del análisis de imágenes médicas, siendo estos fundamentales en la carencia de pruebas de diagnóstico, insuficiencia de recursos económicos para la adquisición de pruebas; la imprecisión y la tardía obtención de los resultados de las pruebas diagnóstico; y la carencia de médicos expertos radiólogos en hospitales para la detección manual mediante imágenes radiológicas (Ozturk, et al., 2020; Gestoso, et al., 2021). De las investigaciones que se han realizado, se destacan los modelos de aprendizaje profundo que implementan técnicas de preprocesamiento en las imágenes y los que implementan modificaciones en la arquitectura de la red que utilizan, entre las cuales se presentan cambios en las capas de clasificación para compensar de que algunos de estos modelos de aprendizaje profundo implementaron conjuntos de imágenes desbalanceados entre clases, debido a que estas técnicas apoyan a la red neuronal convolucional para obtener un mejor resultado en el proceso de clasificación (Lalmuanawma, et al., 2020).

A fin de contribuir en el prediagnóstico automático de la enfermedad COVID-19, en esta tesis se propone un modelo de Red Neuronal Convolucional que permita clasificar radiografías de tórax en las clases COVID-19; y NOCOVID-19 (otras enfermedades respiratorias con afectación pulmonar).

## 1.1 Descripción del problema

Se pretende contar con la atención rápida de los enfermos de COVID-19 en las primeras fases de la enfermedad para evitar el ingreso a unidades de cuidados intensivos o la defunción del paciente por una atención tardía. Desafortunadamente, existe una reducida accesibilidad de pruebas de diagnóstico de COVID-19, por falta de personal médico capacitado para la aplicación de las pruebas, la disponibilidad de pruebas de laboratorio y recursos económicos reducidos por parte del paciente; requiriendo de métodos auxiliares para el prediagnóstico que sean rápidos, fiables y accesibles (Bhattacharya, et al., 2021).

Debido a ello, se han desarrollado diferentes modelos de aprendizaje automático para la prediagnóstico de COVID-19 mediante imágenes radiológicas; sin embargo, muchos de los modelos no se encuentran preparados para ser usados en escenarios reales, debido a que implementan conjuntos de imágenes para entrenamiento de enfermos únicamente con COVID-19 y sujetos sanos, sin considerar a otras enfermedades, ocasionando que un paciente que padezca otra enfermedad respiratoria sea identificado como que se encuentra enfermo con COVID-19. Se han desarrollado investigaciones para distinguir entre COVID-19 y otras enfermedades, sin embargo, la cantidad de imágenes implementadas normalmente es reducida y las clases no suelen estar balanceadas. La revisión de la literatura también revela que en la mayoría de los modelos normalmente no se implementan técnicas de preprocesamiento de imágenes como apoyo en la extracción de características de la patología y en algunos modelos se implementan técnicas de clasificación de *machine learning* que demuestran un desempeño reducido. Además, hay desarrollos que utilizan redes neuronales convolucionales preentrenadas con conjunto de imágenes que no son adecuadas al clasificar imágenes médicas.

Considerando lo anterior, en este trabajo de tesis se atiende el problema de **clasificar entre COVID-19 y NOCOVID-19 (otras enfermedades respiratorias con afectación pulmonar), en el área de prediagnóstico automático basado en el análisis de radiografías de tórax.**

### 1.1.1 Delimitación del problema específico

En este trabajo se desarrolló un método de aprendizaje profundo para la clasificación de radiografías de tórax que presenten hallazgos correspondientes a la patología COVID-19 y hallazgos correspondientes a otras enfermedades respiratorias que no son COVID-19 pero causan afectaciones pulmonares (NOCOVID-19). Para lograr lo anterior, fue necesario extraer las características de las radiografías de tórax implementando una Red Neuronal Convolutiva y clasificarlas en las clases NOCOVID-19 o con COVID-19 de acuerdo con la información médica presentes en la imagen.

Es importante mencionar que, según la literatura, la implementación de Redes Neuronales Convolutivas resulta factible para afrontar la problemática descrita ya que se distingue por trabajar con imágenes a fin de extraer características de estas que resulten útiles para su clasificación en clases específicas (LeCun, et al., 1998); por otro lado, la literatura revela que la implementación de técnicas de preprocesamiento, mejora significativamente la clasificación de imágenes, por lo que como parte del trabajo de tesis se implementaron y evaluaron las técnicas de preprocesamiento más significativas; además, igualmente se evaluaron diferentes clasificadores de aprendizaje profundo buscando aquellos con un mejor rendimiento.

### 1.1.2 Complejidad del problema

La complejidad del problema de esta investigación radica principalmente en los siguientes puntos:

1. Estudio y selección de las mejores técnicas de preprocesamiento para la extracción de características en radiografías de tórax.
2. Conformación de un *dataset* de radiografías de tórax de paciente con hallazgos referentes a las patologías COVID-19 y no COVID-19.
3. Comprensión del proceso de clasificación realizado por una Red Neuronal Convolutiva.
4. Análisis y evaluación de diferentes arquitecturas de Redes Neuronales Convolutivas.
5. Implementación de la Red Neuronal Convolutiva seleccionada.
6. Entrenamiento y extracción de las características presentes en las radiografías de tórax de las diferentes clases.
7. Sintonización de la Red Neuronal Convolutiva consecuentemente del entrenamiento.
8. Obtención de resultados satisfactorios al evaluar el modelo propuesto en condiciones que asemejen al mundo real.

---

## 1.2 Objetivos

### 1.2.1 Objetivo General

Clasificar imágenes de radiografías de tórax en dos clases, siendo estas COVID-19 o NOCOVID-19 implementando una Red Neuronal Convolutiva en conjunto con diferentes técnicas de preprocesamiento para la mejora visual de imágenes.

### 1.2.2 Objetivos Específicos

Para esta investigación se definieron los siguientes objetivos específicos:

- Comprender los conceptos básicos de las imágenes de radiografía de tórax.
- Estudiar las Redes Neuronales Convolutivas y sus aplicaciones en la clasificación de imágenes médicas.
- Seleccionar un modelo de Red Neuronal Convolutiva para la clasificación de imágenes.
- Recopilar y seleccionar radiografías de tórax de pacientes diagnosticados, con COVID-19 y patologías con hallazgos similares a COVID-19 en etapas tempranas de la enfermedad.
- Evaluar técnicas de preprocesamiento de imágenes médicas para realzar características relevantes y la mejora de su calidad visual.
- Combinar un modelo de Red Neuronal Convolutiva y diferentes técnicas de preprocesamiento de imágenes para realizar la tarea de clasificación de radiografías de tórax.
- Realizar experimentación y evaluación del desempeño del sistema propuesto con el conjunto de imágenes recopiladas previamente etiquetadas.

## 1.3 Alcances y Limitaciones

### 1.3.1 Alcances

Los alcances de la investigación realizada son:

- Analizar modelos de Redes Neuronales Convolutivas.
- Analizar el proceso de clasificación en las Redes Neuronales Convolutivas.
- Emplear imágenes de radiografías de tórax en escala de grises.
- Utilizar diferentes técnicas de preprocesamiento

- Implementar una metodología basada en una arquitectura de Red Neuronal Convolutiva para la clasificación de imágenes de radiografía de tórax en las clases COVID-19 y otras enfermedades respiratorias.
- Evaluar el desempeño de la metodología propuesta con parte del conjunto de imágenes recolectadas previamente etiquetadas.

### 1.3.2 Limitaciones

Limitaciones del trabajo realizado son:

- Trabajar con imágenes de radiografías de tórax previamente diagnosticadas por un experto.
- Realizar la clasificación de imágenes de radiografía de tórax en dos clases COVID-19 y NOCOVID-19 (otra enfermedad respiratoria indicando que no es COVID-19).
- No generar como resultado un diagnóstico médico.

## 1.4 Justificación y beneficios

El desarrollo de un modelo de aprendizaje profundo para la detección de COVID-19 a partir de imágenes de radiografía de tórax contribuye en el proceso de prediagnóstico médico, reduciendo la posibilidad de que un médico realice un dictamen erróneo ante síntomas similares. Además, se contribuye a la detección precoz de COVID-19, permitiendo que el usuario proceda a implementar medidas de aislamiento social, reduciendo de esta manera la cantidad de contagios; además de ayudar a que el paciente se atienda rápido y adecuadamente.

Se han desarrollado diferentes trabajos en la detección de COVID-19 y de otras patologías pulmonares, pero presentan desbalance entre las clases y para compensarlo realizan aumento de datos ocasionando un sobre ajuste en la red, algunos modelos no implementan técnicas de preprocesamiento ocasionando que la red neuronal convolutiva realice la extracción de las características sin un apoyo para el realce de estas, además de la implementación de técnicas de clasificación de *Machine Learning*, obteniendo un desempeño dudoso; debido a esto se realizó una recolección ardua de imágenes de radiografías de tórax de las patologías de COVID-19 y patologías con síntomas similares. Se implementaron varias técnicas de preprocesamiento y se evaluaron diferentes redes neuronales convolutivas para observar su desempeño; obteniendo de esta manera un modelo de aprendizaje profundo que obtuvo resultados efectivos y fiables.

## **1.5 Organización de la Tesis**

Este documento está compuesto por seis capítulos, acompañados de anexos y referencias. El capítulo 2 presenta el marco conceptual, en el cual se definen conceptos claves que facilitan la comprensión de este proyecto de investigación. En el capítulo 3 se abordan los antecedentes y el estado del arte, mencionando los trabajos más relevantes para esta investigación. El capítulo 4 describe la metodología empleada en el estudio, detallando las principales contribuciones. El capítulo 5 se enfoca en la experimentación realizada y los resultados obtenidos. Finalmente, el capítulo 6 expone las conclusiones generales de la investigación, los productos desarrollados y las propuestas para futuros trabajos.

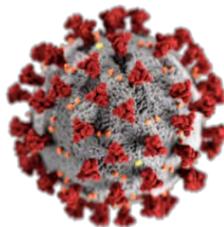
## Capítulo 2

### Marco Conceptual

En este capítulo se presentan los conceptos básicos de la investigación desarrollada, los cuales ayudan en la comprensión de los temas relacionados, proveyendo de la información necesaria y sentando las bases para el entendimiento de los aspectos abordados en el resto del documento.

#### 2.1 COVID-19

Hace unos años se presentó la pandemia causada por la enfermedad infecciosa llamada COVID-19, la cual es producida por el virus SARS-CoV-2 (síndrome respiratorio agudo severo coronavirus 2), se puede observar en la Figura 2.1; el primer registro fue realizado el 8 de diciembre 2019, reportando 27 casos de neumonía de etiología desconocida, localizados en la provincia de Hubei en la ciudad de Wuhan. Siendo reconocida como pandemia por la Organización Mundial de la Salud (OMS) el 11 de marzo del 2020 (Maguiña et al., 2020).



**Figura 2. 1.** Virus del SARS-CoV-2 (CDC, 2020).

La enfermedad COVID-19 demostró ser demasiado contagiosa estimando que presenta un número reproductivo básico entre 1.74-2.91. Transmitiéndose por una persona infectada al toser y destornudar secreciones; o, por el contacto con secreciones respiratorias de una persona infectada. En esta enfermedad por lo general el paciente presenta síntomas de manera leve a grave, manifestándose entre el periodo de tiempo 2 a 14 días después de la exposición al virus (Pérez, 2020; Kanne, et al., 2020).

Las medidas de protección recomendadas son el uso de mascarilla, lavado frecuente de manos, cuarentena (en caso de infección) y distanciamiento social (OMS, 2020). El virus SARS-CoV-2 presenta una predilección por el árbol respiratorio, al penetrar en los pulmones se genera una respuesta inmune anormal del tipo inflamatorio incrementando las citoquinas, agravando al paciente a nivel pulmonar y consecuente generando daño multiorgánico. Desafortunadamente la pandemia de COVID-19 generó repercusión a nivel social, económico y sanitario mundialmente (Maguiña et al., 2020).

## 2.2 Radiografías de tórax

La radiografía es una imagen médica que utiliza la radiación electromagnética ionizante de los rayos X para visualizar el cuerpo humano o partes de él; debido a su pequeña longitud de onda (1 o 2 Amperios), los rayos X tienen capacidad de interacción con la materia. Si la longitud de onda de los rayos es menor, mayor es su energía y penetración (Díaz, 2014).

El cuerpo humano está formado por tejidos y sustancias de diferente densidad, los rayos X pueden ser usados para revelar la estructura interna del cuerpo en una película al iluminar estas diferencias, haciendo uso del término de atenuación o absorción de los fotones que conforman los rayos X al incidir en los tejidos más densos (Pezzotti, 2014).

Debido a su disponibilidad, utilidad y bajo costo, la primera prueba de imagen médica aplicada por los médicos a pacientes con sospecha de COVID-19 suele ser la prueba mediante radiografía de tórax utilizando proyecciones: posterior anterior y lateral en bipedestación (Wong, et al., 2020; Manna, et al., 2020).

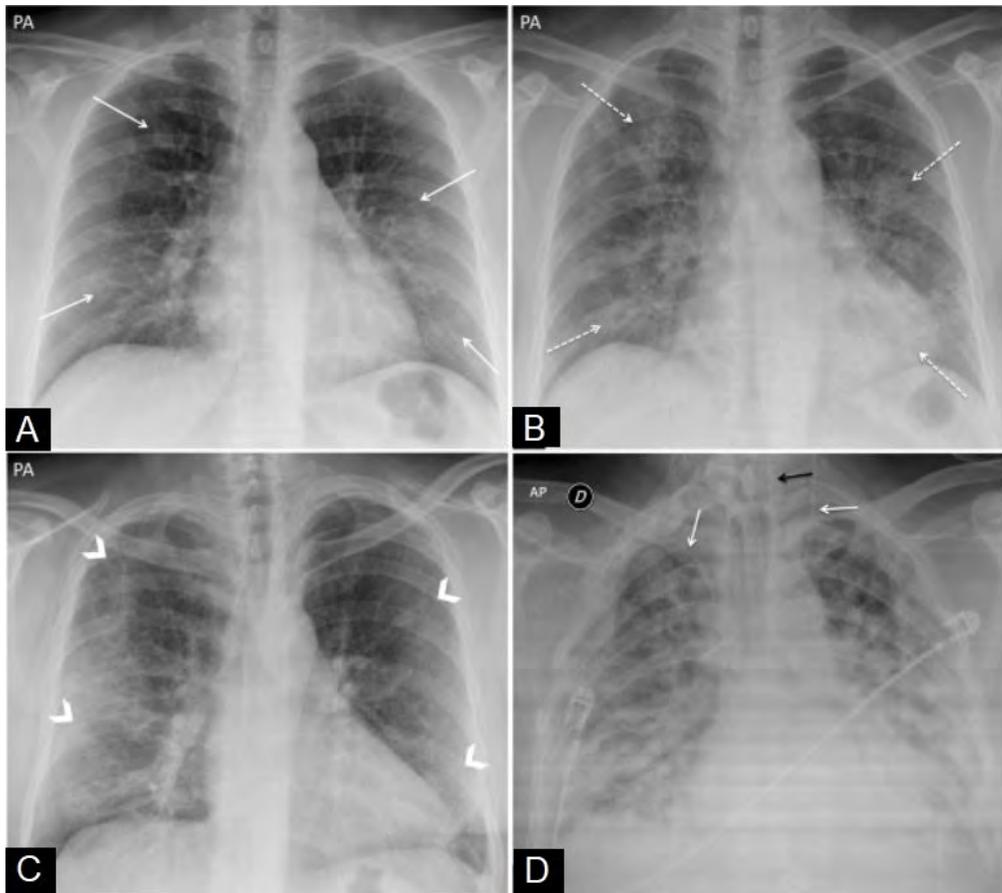
## 2.3 Anormalidades presentes en radiografías de tórax para determinar el prediagnóstico de COVID-19

El prediagnóstico de COVID-19 mediante radiografías de tórax ha obtenido un valor importante en la detección de la patología, siendo aplicadas en conjunto con las pruebas RT-PCR, anticuerpos o de antígenos; además, han sido utilizadas para determinar la gravedad con la que se presenta la patología en el paciente, brindando información que permite determinar el tratamiento y valorar la respuesta terapéutica. Para el apoyo en el diagnóstico, los médicos suelen revisar radiografías en busca de anomalías correspondientes a COVID-19 (Raptis, et al., 2020), siendo aceptado para ser empleado como método de triaje en escenarios que se presenta alta prevalencia de la enfermedad, en centros de salud públicos con acceso reducido a pruebas de diagnóstico, cuando hay disponibilidad de equipo portátil para la captura de radiografías de tórax o para acelerar el proceso de clasificación y determinar el ingreso hospitalario y apoyo en el tratamiento (Martínez, et al., 2021).

Los hallazgos obtenidos en las imágenes de radiografías de tórax de pacientes confirmados con COVID-19 se han dividido en tres categorías, presentadas a continuación.

### 2.3.1 Hallazgos típicos asociados a la patología COVID-19

Entre los hallazgos más comunes se incluye el patrón reticular, las consolidaciones y las opacidades en vidrio deslustrado con morfología redondeada y distribución confluyente o multifocal parcheada. Frecuentemente los hallazgos presentan una distribución periférica, bilateral, y con mayor presencia en los campos inferiores (Wong, et al., 2020), pudiendo ser observados estos hallazgos en la Figura 2.2.

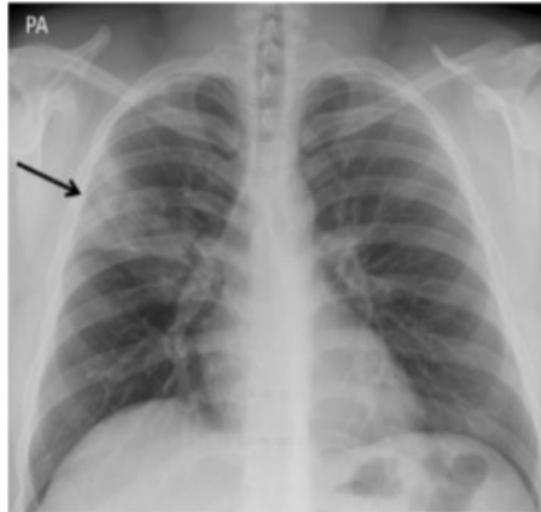


**Figura 2. 2.** Hallazgos típicos de la patología COVID-19 (Martínez, et al., 2021). A) Radiografía de tórax PA, patrón intersticial reticular de predominio periférico. B) Radiografía de tórax PA del mismo paciente 3 días siguiente, presentando tenues opacidades alveolares redondeadas, periféricas y bilaterales. C) Radiografía de tórax con disnea, presenta opacidades periféricas bilaterales en campos superiores, medios e inferiores. D) Radiografía de tórax anteroposterior de paciente años con disnea y COVID-19; presenta múltiples áreas de consolidación confluyente difusas bilaterales.

### 2.3.2 Hallazgos no determinantes para el diagnóstico de COVID-19

Son los hallazgos que se presentan pocas veces en casos de neumonía por COVID-19, entre estos hallazgos se encuentran, las consolidaciones u opacidades en vidrio

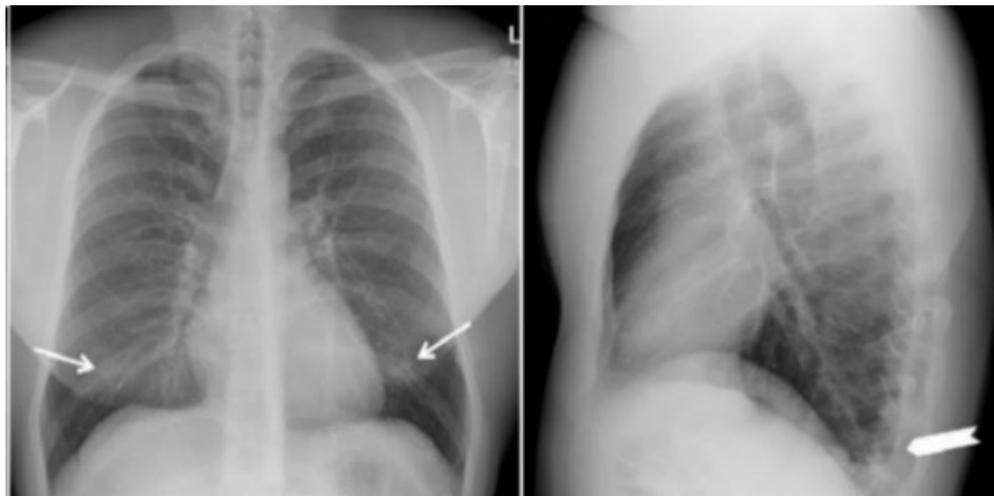
deslustrado con distribución unilateral, central o en los lóbulos superiores (Wong, et al., 2020), pueden observarse en la Figura 2.3.



**Figura 2. 3.** Hallazgos atípicos de neumonía COVID-19. Radiografía de tórax de PA da varón de 28 años con prueba PCR positiva para SARS-CoV-2, demuestra afectación del lóbulo superior derecho (Martínez, et al., 2021).

### 2.3.3 Hallazgos atípicos asociados a la patología de COVID-19

Hallazgos que no se presentan frecuentemente en la neumonía causada por COVID-19, siendo estos el nódulo pulmonar, consolidación lobar, patrón miliar, la cavitación y derrame pleural, (Wong, et al., 2020), pueden observarse en la Figura 2.4.



**Figura 2. 4.** Radiografía de tórax PA y lateral, respectivamente de paciente masculino de 17 años con fiebre y prueba PCR positiva, donde se puede observar ligeros infiltrados bilaterales en campos inferiores del área pulmonar con mínimo derrame pleural en el seno costodiafragmático posterior izquierdo (Martínez, et al., 2021).

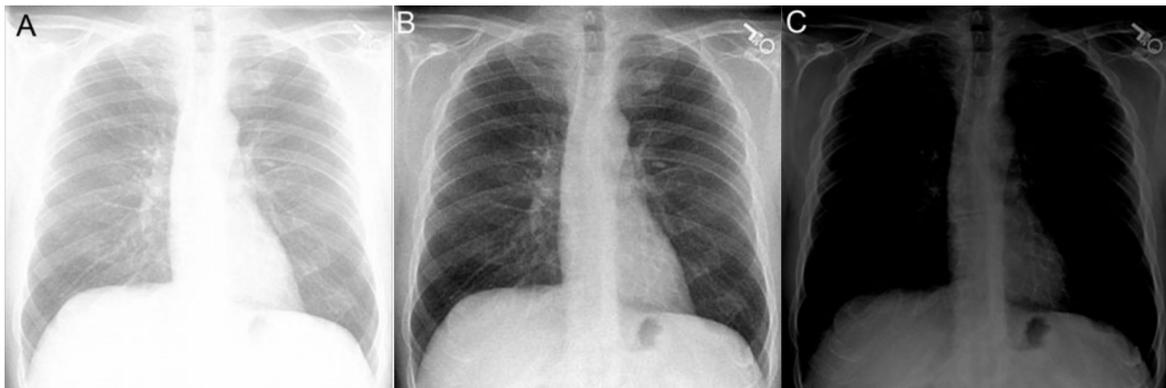
## 2.4 Conceptos sobre la calidad visual en imágenes médicas de radiografía

### 2.4.1 Contraste radiográfico

Es la diferencia de densidad entre regiones vecinas en una radiografía. Las imágenes con un alto contraste radiográfico distinguen notablemente las diferencias de densidad (tonos de gris). El contraste reducido radiográfico se observa en imágenes radiográficas donde las regiones adyacentes tienen una diferencia de baja densidad (Jones & Murphy, 2018; Westra & Sperber, 2001).

### 2.4.2 Subexposición y sobreexposición radiográfica

Una radiografía subexpuesta presenta moteado cuántico (ruido); clínicamente, una radiografía de tórax subexpuesta presenta la condición granulada y mostrará una penetración deficiente de las estructuras mediastínicas; generando una representación inexacta de la anatomía del tórax. Una radiografía sobreexpuesta tendrá una clara falta de moteado cuántico presentando saturación o en casos extremos, quemadas, por lo que la anatomía se borra completamente de la radiografía (Murphy, 2019; Seibert, et al., 2011). En la Figura 2.5 se puede observar el ejemplo de estos dos tipos de alteraciones.



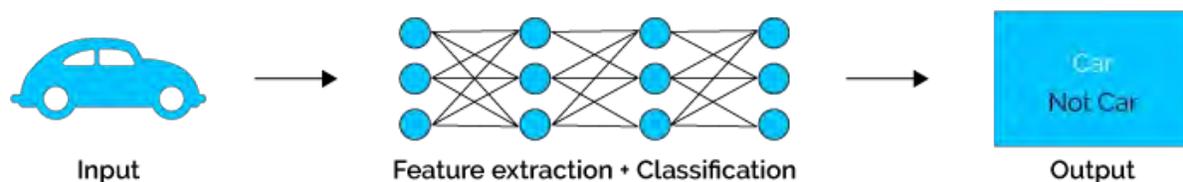
**Figura 2.5.** Ejemplos de radiografías de tórax que presentan (A) Subexposición, (B) Exposición correcta y (C) Sobreexposición. (Seibert & Morin, 2011).

## 2.5 Aprendizaje profundo

El aprendizaje profundo, es una rama de la inteligencia artificial que trata de abordar problemas con mayor nivel intuitivo, postulando que las computadoras aprenden mediante la experiencia, logrando de esa forma comprender el mundo en términos de jerarquía de conceptos, donde cada concepto es definido mediante la

relación a conceptos más simples. El aprendizaje profundo, además de caracterizarse por su profundidad, también considerada su capacidad para aprender las representaciones de los datos con el objetivo de buscar que las computadoras aprendan mediante el reconocimiento de patrones en los datos de entrada, empezando de lo general a lo particular mediante la descomposición del reconocimiento en capas, se puede observar en la Figura 2.6 (González, 2018).

Este conjunto conformado por capas es denominado como un modelo de redes neuronales; los datos que son aprendidos por un modelo se conocen como aprendizaje de representaciones jerárquicas, siendo aprendidas automáticamente por la exposición a los datos implementados para entrenamiento (Chollet, 2017).



**Figura 2. 6.** Representación gráfica general de aprendizaje profundo (Shyam, et al., 2021).

## 2.6 Redes Neuronales Convolucionales

Una Red Neuronal Convolutiva es un tipo de algoritmo implementado en el aprendizaje profundo. Asigna la entrada a un objetivo a través de una serie de transformaciones profundas de datos llamadas capas. Este es un tipo de red neuronal dedicada al procesamiento de datos, y aprenden mediante se le vaya mostrando dichos datos. Estas redes aprenden gradualmente capa a capa, dando lugar al desarrollo de representaciones cada vez más complejas.

Este tipo de red crea propiedades jerárquicas adquiridas a través de su arquitectura profunda al tener varias capas conectadas continuamente, y cuanto más profunda es la red, el proceso de extracción de características mejora (Chollet, 2017; Pereira, et al., 2016; Tajbakhsh, et al., 2016). Para realizar el proceso de extracción de características se emplea la operación matemática denominada convolución, siendo esta un tipo especializado de operación lineal implementado en las redes neuronales convolucionales (Tajbakhsh, et al., 2016; Goodfellow, et al., 2016).

Las redes neuronales convolucionales operan como estructuras jerárquicas en las que las capas de convolución se intercalan con capas de submuestreo, permitiendo extraer tanto características simples como complejas. La forma y la cantidad de capas de estas redes varían según el problema para el cual se diseñen. (Krizhevsky, 2017).

## 2.6.1 Arquitectura de las redes neuronales convolucionales

La estructura principal de una red neuronal convolucional dispone de una capa de convolución para convertir las entradas, como una imagen en un conjunto de características extraídas pasando por un filtro o núcleo (*kernel*) de tamaño definido. Después, las características obtenidas por las capas de convolución proceden a la función de activación y se submuestra mediante la capa de submuestreo (*pooling*) para reducir su dimensionalidad. A finalizar, la estructura agrupada se aplanan en un vector de características unidimensional y sirve como entrada a una red neuronal completa o densamente conectada para su clasificación (capas totalmente conectadas). Este tipo de redes tienen la capacidad de poder implementar múltiples capas de convolución y submuestreo (Yang, 2019); se puede observar en la Figura 2.7, la arquitectura general de este tipo de Red Neuronal.

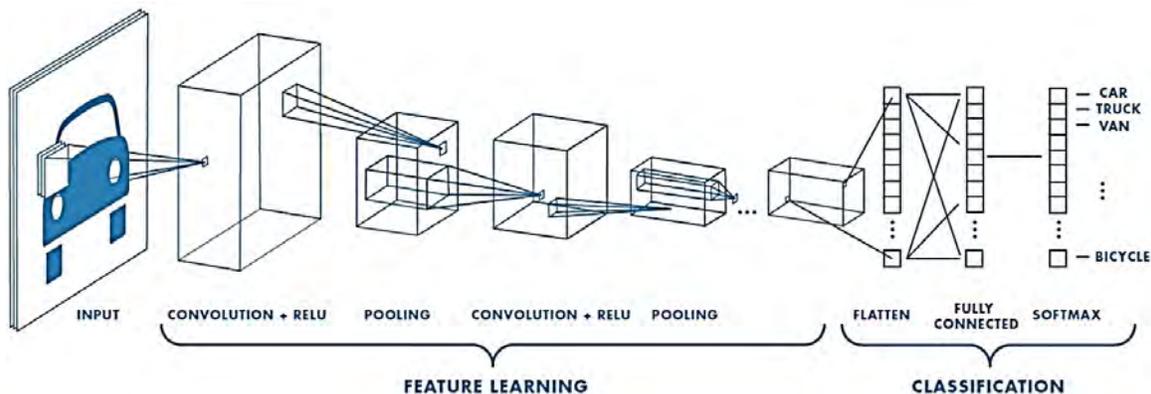


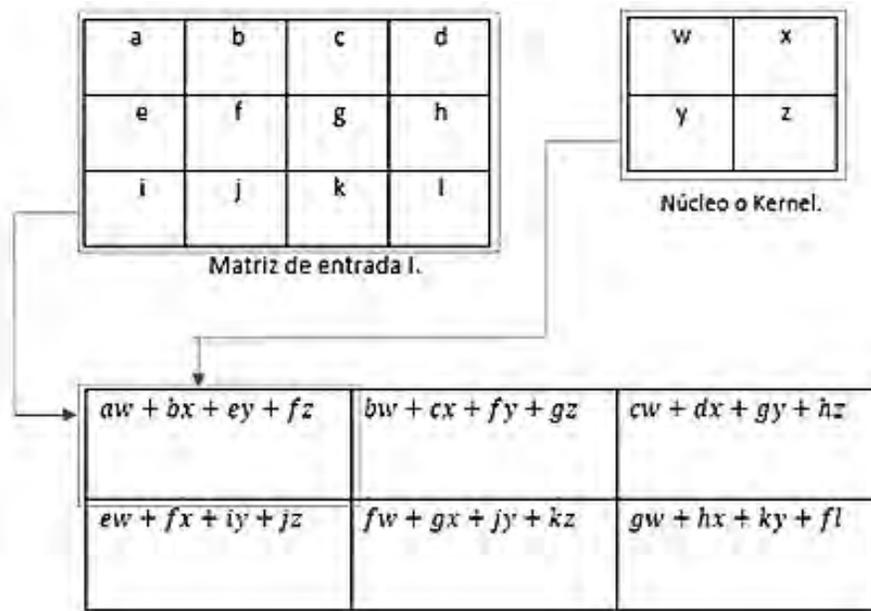
Figura 2. 7. Arquitectura básica de una Red Neuronal Convolucional (Mathworks, 2018).

### Capa de convolución

En las Redes Neuronales Convolucionales las señales de entrada son los píxeles de una imagen. Cuando se tiene una imagen en blanco y negro con  $54 \times 54$  píxeles se usarían 2,916 neuronas. Si esta última fuera en color, gracias a que se necesitan tres canales, se usarían  $54 \times 54 \times 3$ , es decir, 8,748 neuronas de entrada. La convolución es una herramienta matemática que, en las redes neuronales, es capaz de crear relaciones entre píxeles utilizando pequeñas matrices de datos de entrada.

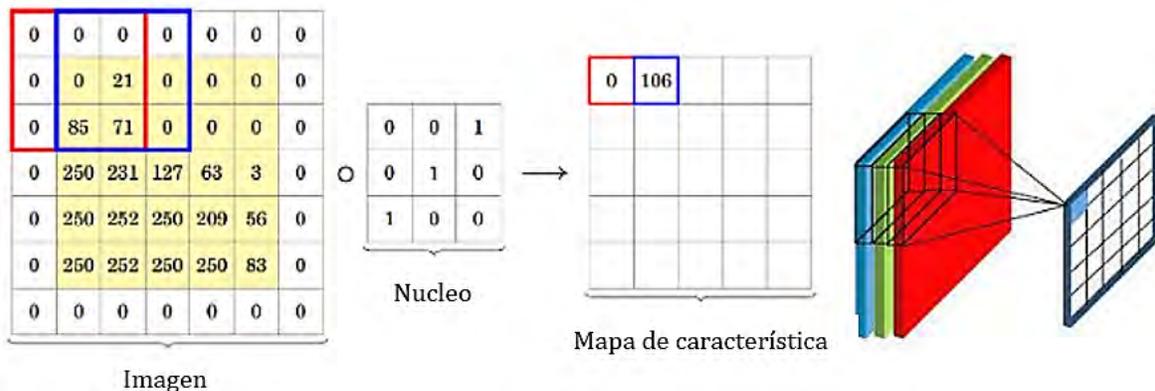
La capa de convolución se integra por un conjunto de filtros denominados como núcleos convolucionales en el cual se realiza una operación de convolución con una entrada determinada generando como salida un mapa de características. El *kernel* es una rejilla de número discretos inicializados de forma aleatoria (Khan, 2018). El proceso de convolución consiste en realizar la sumatoria de todas las multiplicaciones con el *kernel* y cada campo receptivo local (matriz de entrada de la sección de la imagen), que

conforma la imagen, el barrido inicia de izquierda a derecha de arriba hacia abajo, como se observa en la Figura 2.8.



**Figura 2. 8.** Ilustración grafica de operaciones de la convolución (Goodfellow, et al., 2016).

La capa de convolución tiene el objetivo, el aprender todas las representaciones de las características de una entrada, proporcionando un medio para trabajar con entradas de tamaño variable. Para implementar la convolución en las matrices de entrada, se coloca un filtro en el primer píxel de la imagen y se multiplican los valores anidados. Para evitar problemas de dimensionalidad, se implementa una técnica llamada *padding*, que consiste en agregar filas y columnas de ceros a los bordes de la matriz de entrada. El *kernel* se desliza sobre la entrada y la salida será un mapa de activación cuyo valor actual se obtiene de sumar las convoluciones entre el filtro y la entrada (Khan, 2018). El proceso que realiza la capa de convolución puede ser observado en la Figura 2.9.



**Figura 2. 9.** Representación esquemática de la operación de convolución (Goodfellow, et al., 2016).

Los núcleos de las primeras capas convolucionales detectan características de bajo nivel, incluidos bordes y curvas, a diferencia de las capas superiores, los núcleos de ejecución se utilizan para codificar características más abstractas, apilando varias capas convolucionales y de agrupación se extraen representaciones de características de nivel superior. La representación formal del proceso de convolución, se muestra en la Ecuación 4.8,

$$y_{i''j''d''} = b_{d''} + \sum_{i'=1}^{H'} \sum_{j'=1}^{W'} \sum_{d'=1}^{D'} k_{i'j'd'} \times x_{S_h(i''-1)+i'-P_h^-, S_w(j''-1)+j'-P_w^-, d', d''} \quad (2.1)$$

donde,  $y_{i''j''d''}$  es el mapa de características obtenido,  $b_{d''}$ , es el sesgo sumado al resultado de la convolución entre el kernel  $k_{i'j'd'}$  y las neuronas de entrada  $x$ . El relleno (*padding*) de arriba-izquierda, está representado por  $P_h^-, P_w^-$ .  $S_h$  es el paso en altura y  $S_w$  es el paso en anchura (Vedaldi & Lenc., 2015).

## Capa de muestro

El *pooling* es una técnica de reducción dimensional que consiste en centrar una región de tamaño  $k \times k$  como filtro de *pooling*. En esta capa se realiza el cálculo del valor de cada región, implementando el valor máximo o la media de todos los valores. En el caso de utilizar el valor máximo, la operación de *pooling* se denomina, *max pooling*. La reducción del tamaño puede ser significativa, y en la mayoría de los casos, el tamaño puede reducirse al menos a la mitad. En la Figura 2.10, se muestra cuando se aplica una capa de *max pooling* implementando un *kernel*  $2 \times 2$  en la última subregión de la imagen, finalmente se determina con un valor máximo de 9 (Khan, 2018).

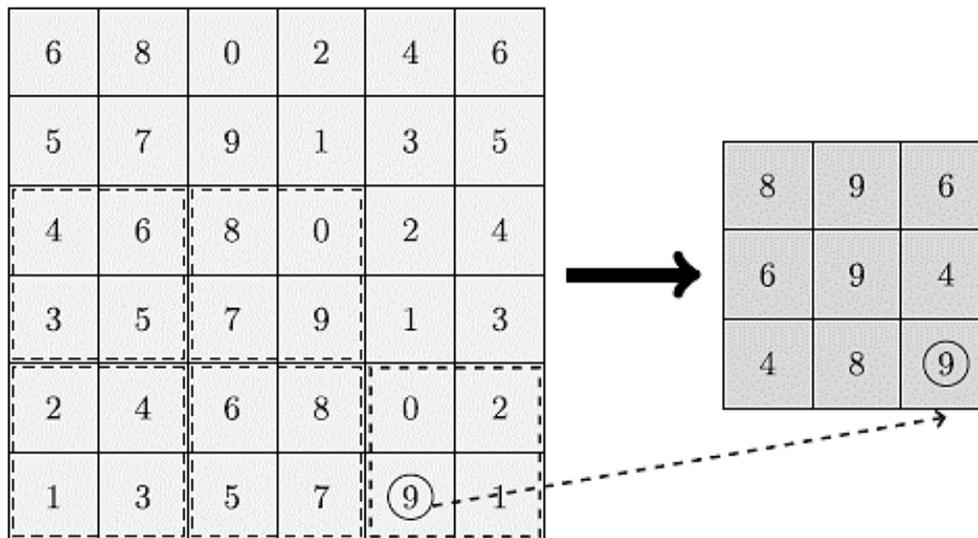


Figura 2. 10. Max pooling bidimensional, aplicando un filtro de  $2 \times 2$ .

## Aplanamiento

Los resultados de las operaciones de convolución y agrupación son matrices bidimensionales para las imágenes en escala de grises o matrices tridimensionales de imágenes en color. Para alimentar estas salidas para el aprendizaje posterior de las redes neuronales *feed-forward* se caracterizan por ejecutar el procesamiento de datos en una sola dirección, distinguiéndose tres capas principales de neuronas: la capa de entrada, donde se reciben los datos a procesar; la capa intermedia, donde se da el procesamiento propiamente dicho y la capa de salida es recomendable remodelar estas matrices bidimensionales o tridimensionales en un vector de características unidimensional. Este proceso se denomina aplanamiento, con el cual se puede realizar el apilamiento de cada fila o columna en un orden secuencial, y luego a diferentes profundidades. En general, para matrices bidimensionales del tamaño  $n \times n$ , el vector unidimensional aplanado tiene elementos  $n^2$ , por ejemplo, para imágenes grises de tamaño  $n \times n \times 1$ .

Si el núcleo de convolución tiene un tamaño  $3 \times 3$  y el número de neuronas ocultas es  $m = 16$ , las características extraídas de la convolución tienen un tamaño de  $(n - 2) \times (n - 2) \times m$  sin relleno. Si la agrupación se realiza en una cuadrícula  $k \times k$  con un intervalo  $k$  (sin solapamiento), entonces las características agrupadas se convierten en  $(n - 2)/k \times (n - 2)/k \times m$  (Goodfellow, et al., 2016).

### 2.6.2 Redes Neuronales Convolucionales implementadas

En el siguiente apartado se describe de manera sintetizada los modelos de redes neuronales convoluciones implementados en el análisis y selección de clasificador, para el diseño del modelo propuesto. Los cuales fueron sometidos a experimentación en el Capítulo 5 en este trabajo de tesis.

#### ResNet50

ResNet50 es una red neuronal residual de 50 capas conocida por su estructura simple y eficaz, ampliamente utilizada en diversas aplicaciones, como se muestra en la Figura 2.11; su diseño incluye bloques residuales donde solo algunos mapeos de identidad requieren ajustes mediante capas convolucionales de  $1 \times 1$  para igualar dimensiones. Esta red resuelve el problema de desvanecimiento del gradiente en redes profundas, ya que los gradientes pueden retroceder directamente a través de conexiones de salto, mejorando su rendimiento en clasificación de imágenes y detección de objetos. ResNet50, con más de 23 millones de parámetros y utiliza bloques residuales para aprender características en distintos niveles de abstracción.

Finalmente, emplea capas de *pooling*, totalmente conectadas y una de salida para completar tareas específicas, como la clasificación (He et al., 2016).

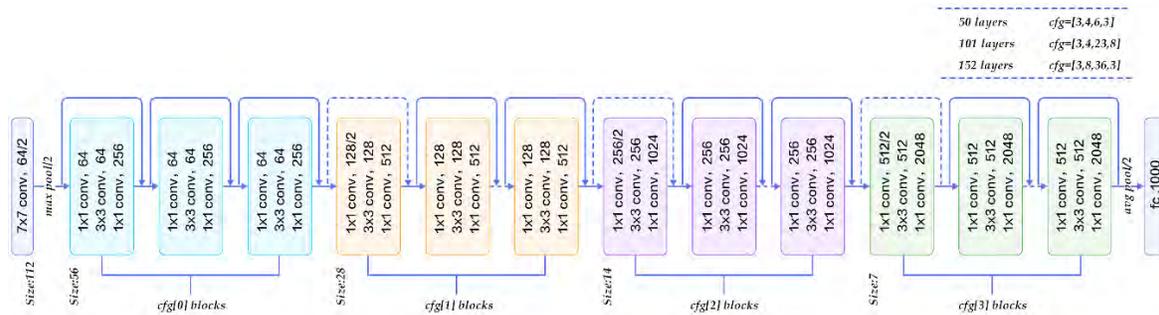


Figura 2. 11. Arquitectura de la Red Neuronal Convolutional ResNet (Burgal, 2018).

## VGG-16

El modelo presenta como entrada una imagen RGB de tamaño fijo de  $224 \times 224$  píxeles. En el reconocimiento de imágenes a gran escala, la imagen pasa a través de varias capas convolucionales (conv) que emplean filtros pequeños de  $3 \times 3$ . El nombre VGG-16 proviene de la cantidad total de 16 capas en el modelo. Su arquitectura se distingue por ser simple y uniforme, utilizando únicamente capas convolucionales de  $3 \times 3$  con un *stride* de 1, y capas de *pooling* de  $2 \times 2$  con *stride* de 2.

No incorpora técnicas avanzadas como convoluciones dilatadas o separables en profundidad. VGG-16 es una Red Neuronal Convolutional profunda que aplica convoluciones  $3 \times 3$  y capas de *pooling*  $2 \times 2$  para extraer características de las imágenes. Se conforma con 13 capas convolucionales, 5 capas de *pooling*, 3 capas totalmente conectadas, seguidas de una capa de salida. En la Figura 2.12, se puede observar la arquitectura del modelo desarrollado para el conjunto de datos ImageNet (Simonyan, 2014).

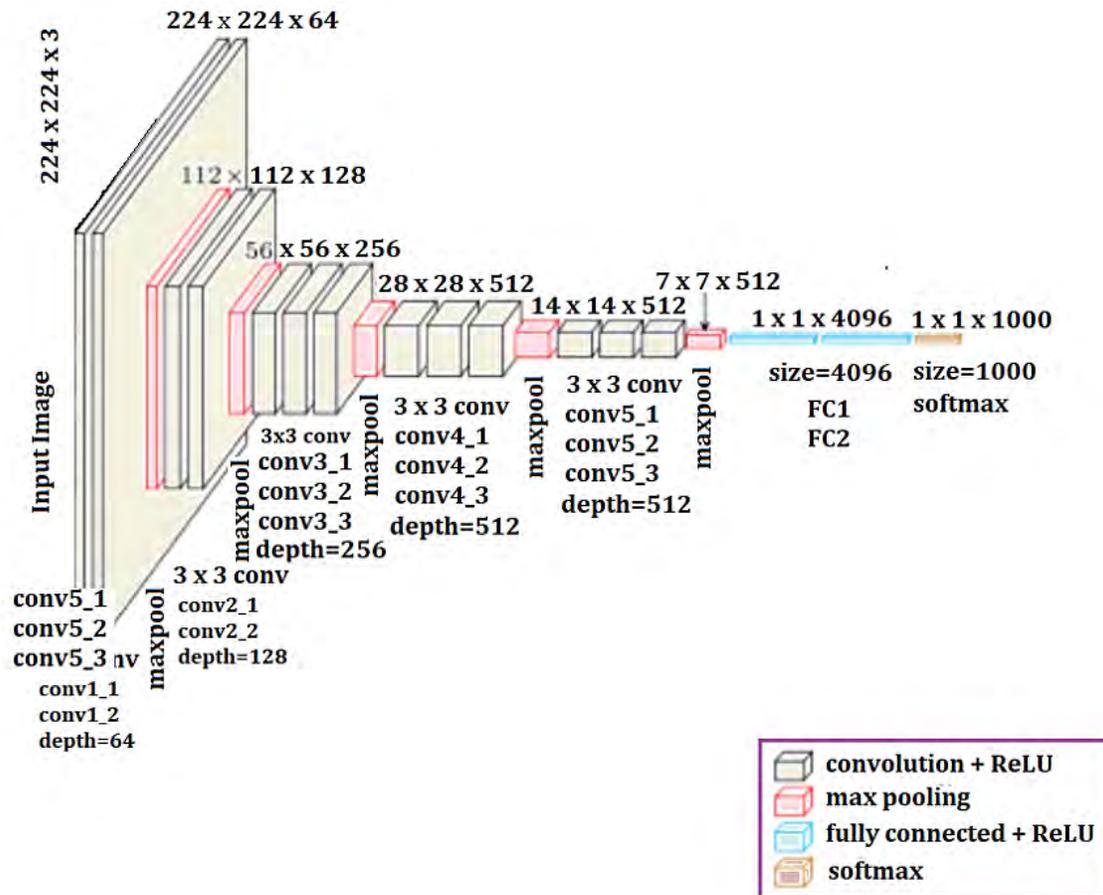


Figura 2. 12. Arquitectura de la Red Neuronal Convolutiva VGG-16 (Dey, 2018).

## VGG-19

Las arquitecturas VGG están formadas por *stacks* lineales de bloques que incluyen varias capas convolucionales, una función de activación no lineal y una capa de *max pooling*, seguidas de tres capas completamente conectadas y una capa *softmax* al final. La arquitectura VGG-19 consta de cinco bloques: los dos primeros tienen dos capas convolucionales con 64 y 128 filtros, respectivamente; el bloque intermedio tiene tres capas con 256 filtros, y los dos últimos cuentan con tres capas cada uno, con 512 filtros por capa. El número 19 corresponde al total de capas entrenables: 16 convolucionales y 3 completamente conectadas. Las capas convolucionales tienen un campo receptivo de  $3 \times 3$ , un *stride* de  $1 \times 1$  y un *padding* de 1 píxel, mientras que las operaciones de max pooling emplean un *kernel* de  $2 \times 2$  y un *stride* de  $2 \times 2$ . Además, todas las capas ocultas utilizan la función de activación ReLU (Simonyan, 2014). En la Figura 2.13, se puede observar la arquitectura VGG-19.

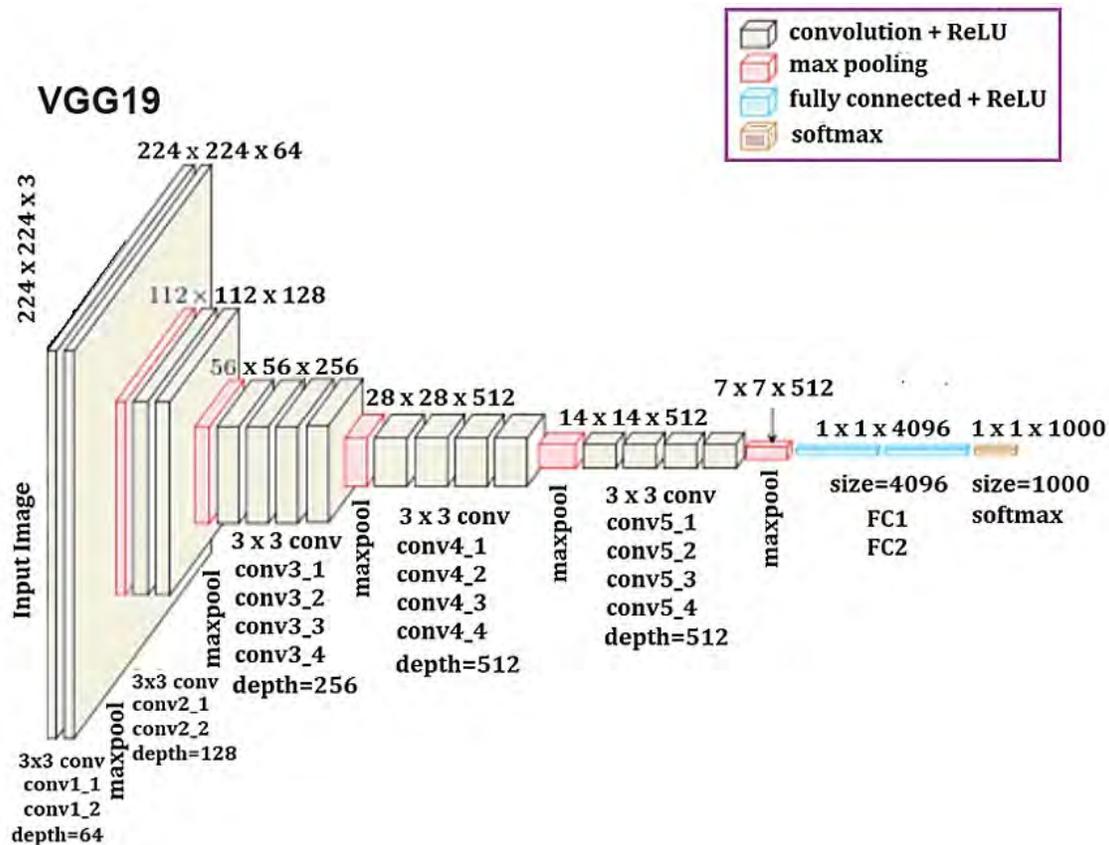


Figura 2. 13. Arquitectura de la Red Neuronal Convolutiva VGG-19 (Dey, 2018).

## Xception

Xception, cuyo nombre proviene de "Extreme Inception", es una innovación en el diseño de redes neuronales convolucionales como una mejora de la arquitectura Inception. Su característica principal es el uso de convoluciones separables en profundidad, las cuales dividen las operaciones en las dimensiones espaciales y de profundidad, reduciendo considerablemente el número de parámetros y el costo computacional sin perder capacidad representativa. La estructura de Xception se organiza en bloques de convoluciones separables, donde cada bloque combina una convolución separable en profundidad con una transformación lineal mediante una convolución  $1 \times 1$ , optimizando la captura de patrones complejos con menos parámetros.

Además, Xception tiene un flujo de entrada que extrae las características iniciales y un flujo de salida que las refina para realizar las predicciones finales, todo ello con la ayuda de conexiones de salto, inspiradas en ResNet, que facilitan un flujo eficiente de información. Utiliza convoluciones separables en profundidad globales en las capas finales para comprender contextos globales y relaciones de largo alcance. Durante el proceso de entrenamiento, Xception aprovecha el aumento de datos, que aplica

transformaciones aleatorias a los datos de entrada para mejorar la capacidad de generalización, y la normalización por lotes, que acelera y estabiliza la convergencia. Además, Xception es ideal para el aprendizaje por transferencia, ya que, al ser preentrenada en grandes conjuntos de datos como ImageNet, puede ser ajustada para tareas específicas utilizando conjuntos de datos más pequeños. Su diseño escalable y eficiente sigue siendo influyente en tareas de visión por computadora y refleja la evolución continua de las arquitecturas de redes neuronales (Chollet, 2017). En la Figura 2.14, se puede observar la arquitectura de la Red Neuronal Convolutiva Xception.

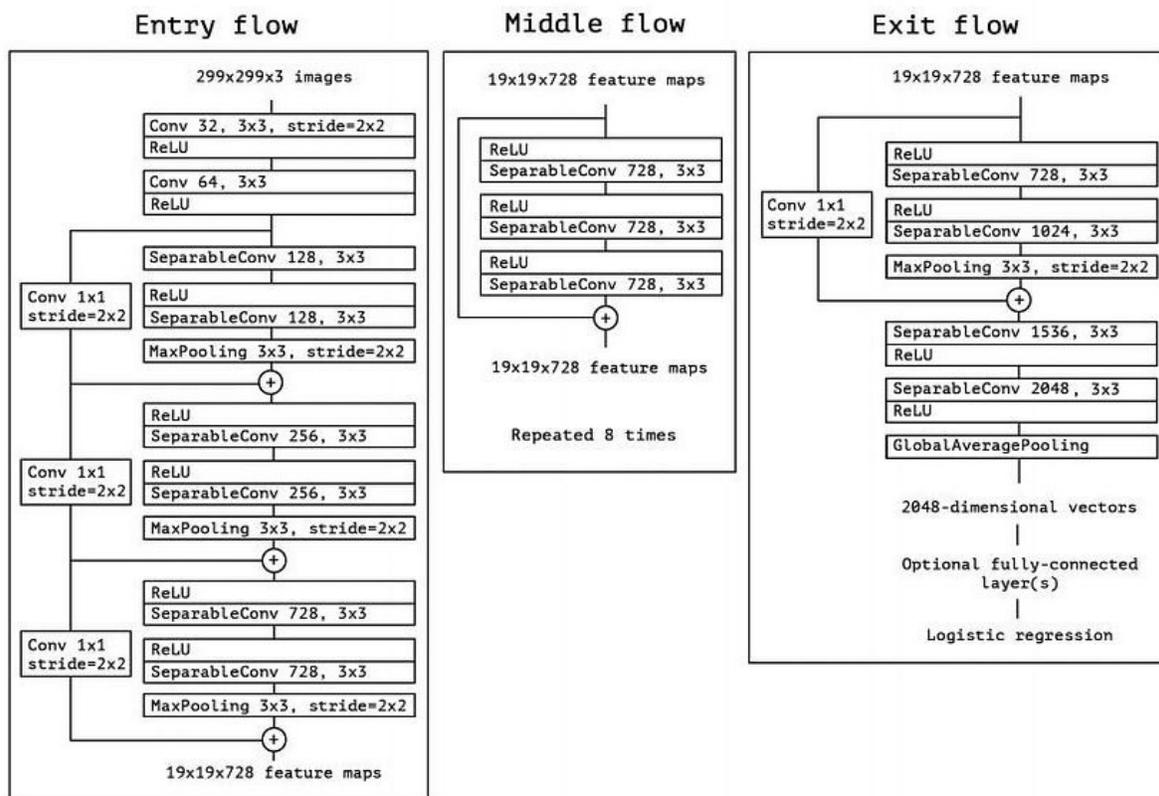
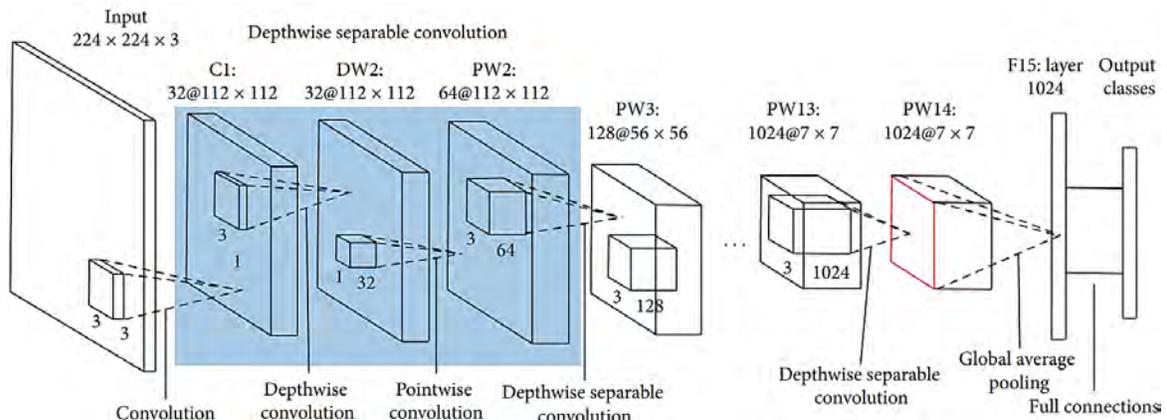


Figura 2. 14. Arquitectura de la Red Neuronal Convolutiva Xception (Chollet, 2017).

## MobileNet

MobileNet utiliza convoluciones separables en profundidad, una técnica que divide una convolución estándar en dos partes: una convolución en profundidad, que aplica un filtro único a cada canal de entrada, y una convolución  $1 \times 1$ , conocida como convolución de puntos, que combina las salidas de la convolución en profundidad. Este enfoque reduce significativamente el número de parámetros en comparación con las redes que emplean convoluciones estándar con la misma profundidad. Al separar los filtros espaciales y de profundidad en dos etapas, MobileNet disminuye la carga computacional y los parámetros de la red, mejorando su eficiencia en términos de

recursos y tiempo de ejecución (Howard et al., 2017). En la Figura 2.15, se puede observar la arquitectura de la Red Neuronal Convolutacional.



**Figura 2. 15.** Arquitectura de la Red Neuronal Convolutacional MobileNet (Westphal, Seitz, 2020).

## 2.7 Conceptos básicos para la implementación de modelos de aprendizaje profundo

### 2.7.1 Hiperparámetros

Los hiperparámetros es todo parámetro que puede ser modificado para alterar el desempeño de una red neuronal (Chollet, 2017).

### 2.7.2 Optimizador de aprendizaje Adadelata

La optimización de Adadelata es un método de descenso de gradiente estocástico que se basa sobre la tasa de aprendizaje adaptativo por dimensión, para abordar los inconvenientes de la continua disminución de las tasas de aprendizaje, a lo largo de la capacitación y la necesidad de una tasa de aprendizaje global seleccionada manualmente (Zeiler, 2012).

### 2.7.3 Transferencia de Aprendizaje

Se basa en utilizar redes neuronales que han sido entrenadas con anterioridad para una determinada tarea de aprendizaje profundo; realizando modificaciones que consisten en adaptar la red, para ser implementado en una tarea similar con datos diferentes (Tajbakhsh, et al., 2016; Dipanjan, 2018; Brownlee, 2017).

## 2.7.4 Ajuste fino

Ajuste fino es un proceso que se utiliza después de hacer transferencia de aprendizaje y consiste en tener un algoritmo preentrenado y ajustarlo a los datos que requiera el problema; en redes neuronales se ajustan las capas ocultas y la capa de salida (Peng & Wang, 2020).

## 2.7.5 Freezing

*Freezing* es una técnica utilizada en modelos de aprendizaje profundo que consiste en no modificar los valores de los parámetros de las capas ocultas en el entrenamiento, solamente se van a actualizar los parámetros de la capa de salida (Gugger & Howard, 2020).

## 2.7.6 Aumento de datos

Las Redes Neuronales Convolucionales dependen en gran medida de grandes cantidades de imágenes para evitar el famoso sobreajuste; lamentablemente muchos desarrollos no tienen acceso a un alto número de imágenes, por ejemplo, en el área de implementación de modelos de aprendizaje utilizando imágenes médicas. Debido a esto se ha implementado el aumento de datos, que es un conjunto de técnicas que mejoran el tamaño y calidad de los datos. Entre estas técnicas se encuentran las de rotar, cortar, saturar, acercar, alejar las imágenes (Shorten & Khoshgoftaar, 2019).

# 2.8 Métricas de evaluación de los modelos de aprendizaje profundo

## 2.8.1 Exactitud

La exactitud (*accuracy*) es una métrica para evaluar un modelo de clasificación e indica cuántas predicciones detectó correctamente y se calcula con el número total de predicciones correctas dividido por el número total de predicciones,

$$Exactitud = \frac{TP+TN}{TP+FN+FP+TN} \quad (2.2)$$

donde, *TP* (*True Positive*) se refiere a los verdaderos positivos, *TN* (*True Negative*) son los verdaderos negativos, *FN* (*False Negative*) son los falsos negativos y *FP* (*False Positive*) son los falsos positivos.

## 2.8.2 Precisión

La precisión es una métrica que indica que tan probable es que sea correcta una predicción dada y se obtiene con las predicciones correctas de la clase dividido por las predicciones correctas de la clase más los falsos positivos.

$$\text{Precisión} = \frac{TP}{TP+FP} \quad (2.3)$$

donde,  $TP$  (*True Positive*) se refiere a los verdaderos positivos y  $FP$  (*False Positive*) son los falsos positivos.

## 2.8.3 Sensibilidad

La Sensibilidad (*Recall*) es una métrica que indica la probabilidad de que detecte correctamente una clase y se calcula con las predicciones correctas de la clase dividido por las predicciones correctas de la clase más los falsos negativos.

$$\text{Sensibilidad} = \frac{TP}{TP+FN} \quad (2.4)$$

donde,  $TP$  (*True Positive*) se refiere a los verdaderos positivos y  $FN$  (*False Negative*) son los falsos negativos.

## 2.8.4 Valor-F1

El Valor-F1 (F1-Score) es otra medida de exactitud y se calcula utilizando la precisión y la sensibilidad, esta medida es útil cuando las clases tienen distinto número de ejemplos.

$$\text{Valor F1} = 2 * \frac{\text{precisión} * \text{sensibilidad}}{\text{precisión} + \text{sensibilidad}} \quad (2.5)$$

## 2.8.5 Matriz de confusión

Una matriz de confusión es un método de visualización para los resultados del algoritmo clasificador. Siendo esta una tabla que desglosa el número de instancias de los casos reales de una clase frente al número de instancias previstas en la predicción para esa clase. En la Tabla 2.1, se observa la distribución de los casos con respecto a la matriz de confusión empleada (Beitzel, 2006).

- Verdaderos Positivos: cuando el caso es positivo y el modelo lo determina como positivo.
- Verdaderos Negativos: cuando el caso es negativo y el modelo lo determina como negativo.
- Falsos Positivos: cuando el caso es negativo y el modelo lo determina como positivo.
- Falso Negativo: cuando el caso es positivo y el modelo lo sitúa como negativo.

		Predicción	
		Positivos	Negativos
Caso Real	Positivos	Verdaderos Positivos	Falsos Negativos
	Negativos	Falsos Positivos	Verdaderos Negativos

Tabla 2. 1. Distribución de casos en matriz de confusión.

---

## Capítulo 3

### Estado del arte

En este capítulo se presentan brevemente los trabajos más relevantes en relación con el desarrollo e implementación de modelos de aprendizaje profundo para la clasificación de COVID-19 y otras enfermedades respiratorias; se consideraron trabajos de investigación que utilizaron modelos de Redes Neuronales Convolucionales que implementaron imágenes de radiografías de tórax, técnicas de preprocesamiento de imágenes de radiografía, métricas de evaluación de modelos de aprendizaje profundo y bases de datos de radiografías de tórax.

#### 3.1 Antecedentes

En esta sección se presentan un trabajo que fue desarrollado en el Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET); y abordo un tema relacionado con este trabajo de investigación desarrollado.

#### **Detección de anomalías en mamografías utilizando la Red Neuronal Con-volucional AlexNet (Matuz, 2017)**

En este trabajo se desarrolló una metodología para detectar anomalías en mamografías utilizando una Red Neuronal Convolutiva. La propuesta se dividió en dos etapas: primero, el preprocesamiento de imágenes, y segundo, el diseño y la caracterización de la red convolutiva basada en la arquitectura AlexNet. La implementación se evaluó empleando la base de datos MIAS (322 mamografías) y una muestra de 250 imágenes de DDSM. Se realizaron clasificaciones ajustando diferentes parámetros del modelo, creando cinco clasificadores para distinguir mamografías sanas de aquellas con algún padecimiento. El mejor desempeño se obtuvo con imágenes en formato PNG, a color, con una resolución ajustada, 50 épocas de entrenamiento y una tasa de aprendizaje de 0.001. Este modelo alcanzó una exactitud del 92%, una sensibilidad del 88% y una especificidad del 96%.

#### 3.2 Trabajos relacionados

En esta sección se presenta a manera de síntesis los trabajos más importantes relacionados con el desarrollo e implementación de modelos de aprendizaje profundo en la detección de COVID-19 y otras enfermedades respiratorias, utilizando Redes Neuronales Convolucionales.

### 3.2.1 Implementación de diferentes técnicas de preprocesamiento

#### InstaCovNet-19: Un modelo de clasificación de aprendizaje profundo para la detección de pacientes con COVID-19 utilizando la radiografía de tórax (Gupta, et al., 2020)

Este estudio propone un sistema automatizado basado en aprendizaje profundo para detectar COVID-19 en radiografías de tórax. Se utilizaron modelos preentrenados (ResNet101, Xception, InceptionV3, MobileNetV2 y NASNet) combinados mediante apilamiento integrado para optimizar resultados con un conjunto de datos limitado; se puede observar el modelo desarrollado en la Figura 3.1. El modelo clasifica las imágenes en dos categorías (COVID y no COVID) y tres categorías (COVID, neumonía y normal). Tras un ajuste del desequilibrio en los datos, se entrenó con imágenes balanceadas. Se aplicaron técnicas avanzadas de preprocesamiento, logrando en la clasificación binaria una exactitud del 99.53%, precisión del 100% y sensibilidad del 99%, y en la clasificación de tres clases, una exactitud del 99.08% con métricas similares.

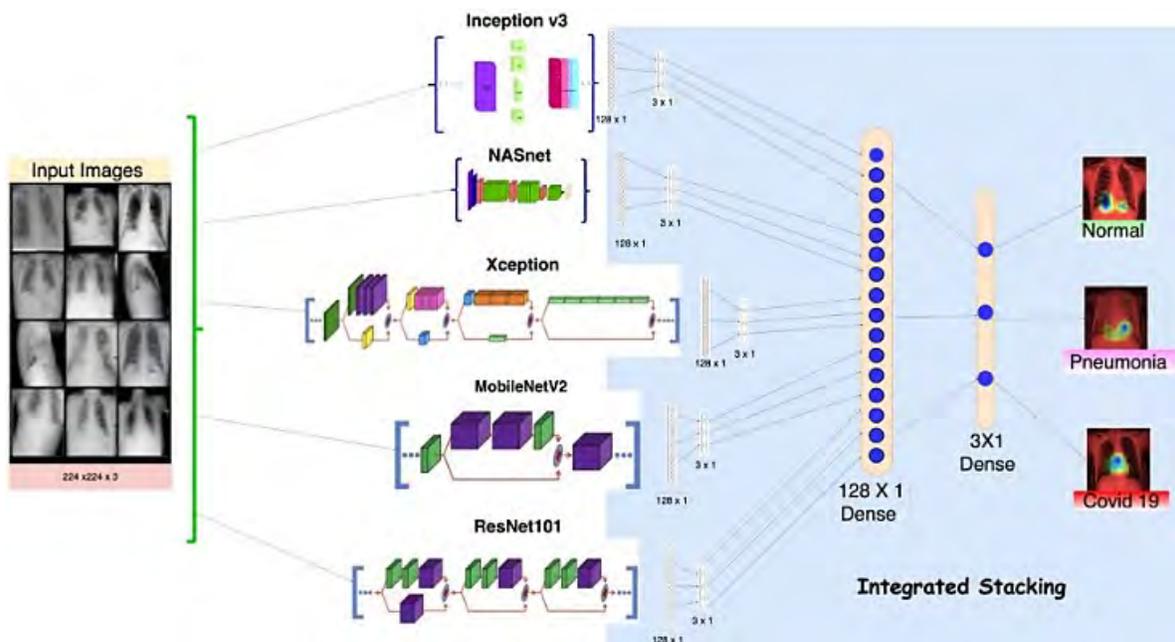
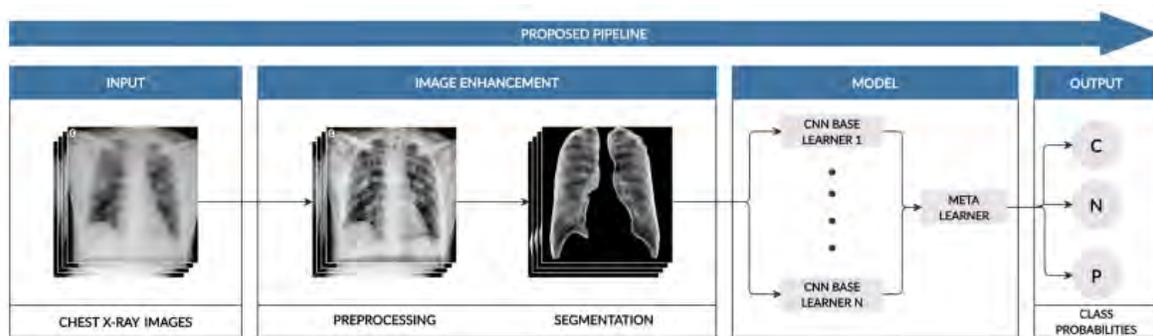


Figura 3. 1. InstaCovNet-19 Modelo apilado integrado (Gupta, et al., 2020).

## COVIDScreen: Marco de aprendizaje profundo explicable para el diagnóstico diferencial de COVID-19 mediante radiografías de tórax (Singh., et al, 2021)

Este trabajo presenta un modelo de aprendizaje profundo para la detección temprana de COVID-19 mediante radiografías de tórax. Incluye técnicas de preprocesamiento como la técnica Ecuilización Adaptativa del Histograma Limitada por el Contraste (CLAHE), segmentación pulmonar con U-Net y aumento de datos con redes generativas adversarias, lo que mejoró la precisión general en un 6%. El modelo utiliza un conjunto apilado de redes neuronales convolucionales (VGG-16, ResNet-50, DenseNet-121 y DenseNet-169) con Naive Bayes como meta-aprendiz, clasificando radiografías en tres categorías: COVID-19, neumonía y normal. Con un conjunto de datos de 15,465 imágenes, el modelo alcanzó un 98.67% de exactitud, una puntuación Kappa de 0.98 y Valor-F1 de 100%, 98% y 98% para COVID-19, normal y neumonía, respectivamente. Se puede observar el modelo desarrollado en la Figura 3.2.

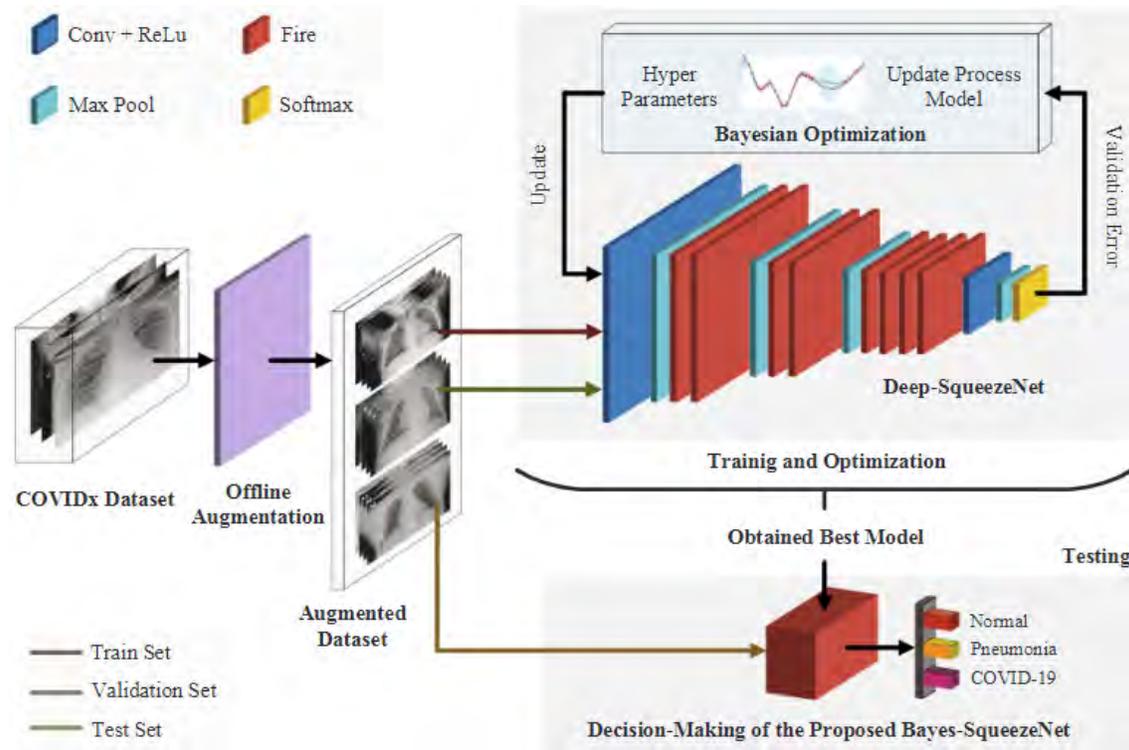


**Figura 3. 2.** Proceso propuesto funciona de la siguiente manera: entrada de las imágenes, etapa de preprocesamiento, seguida de la segmentación, introducen simultáneamente en múltiples modelos y clasificación por el meta-aprendizaje en una de las tres clases: COVID-19 (C), Normal (N) y Neumonía (P) (Singh., et al, 2021).

## COVIDiagnosis-Net: Diagnóstico basado en Deep Bayes-SqueezeNet de la enfermedad por coronavirus 2019 (COVID-19) a partir de imágenes de radiografías de tórax (Ucar., et al, 2020)

Este trabajo propone un modelo de aprendizaje profundo basado en la red SqueezeNet, optimizada mediante Bayes, para la detección de COVID-19. Utiliza un conjunto de datos inicial desequilibrado de 5,954 radiografías (76 de COVID-19, 1,583 normales y 4,295 de neumonía), ampliado mediante técnicas de aumento que incluyen reflejo, ruido, recorte y ajuste de brillo y luminosidad. Tras el aumento, los datos se dividieron en subconjuntos para entrenamiento, validación y prueba. El modelo entrenado, optimizado y validado en paralelo, alcanzó una exactitud del 98.3% en la clasificación de tres clases (COVID-19, normal y neumonía) y del 100% en la detección

exclusiva de COVID-19(entre otras clases). Se puede observar el modelo desarrollado en la Figura 3.3.



**Figura 3. 3.** Arquitectura del sistema de diagnóstico basado en Bayes-SqueezeNet (Ucar., et al, 2020).

### **Detección de COVID-19 con radiografías de tórax a través del clasificador de bosque aleatorio utilizando una hibridación de características optimizadas para CNN y DWT profundos (Mostafiz., et al, 2020)**

Este estudio propone un modelo automático para detectar COVID-19 en radiografías de tórax mediante una combinación de redes neuronales convolucionales profundas y la transformada wavelet discreta (DWT). El proceso incluye preprocesamiento (difusión anisotrópica y ecuilización del histograma), segmentación pulmonar, extracción de características híbridas (red neuronal y DWT), y optimización mediante mRMR y RFE. Un algoritmo de bosques aleatorios utiliza el vector optimizado para la detección. Usando un conjunto de datos de 4,809 imágenes (790 de COVID-19, 1,215 de neumonía viral, 1,304 de neumonía bacteriana y 1,500 normales), el modelo alcanzó una precisión global superior al 98.5%.

## Clasificación COVID-19 de imágenes de radiografías utilizando redes neuronales profundas (Keidar, et al., 2021)

Los autores desarrollaron un modelo de aprendizaje profundo para detectar COVID-19 en radiografías de tórax y recuperar imágenes similares según los resultados del modelo. Usaron 1,384 radiografías de pacientes con COVID-19 y 1,024 de pacientes sin COVID, procesadas mediante aumento de datos (brillo, giro horizontal, rotación de 7 grados y CLAHE), normalización y segmentación pulmonar. El clasificador es un ensamble de redes preentrenadas (ResNet34, ResNet50, ResNet152 y VGG-16). Obtuvo una precisión del 90.3%, especificidad del 90%, sensibilidad del 90.5% y un AUC de 0.96. Se puede observar el modelo desarrollado en la Figura 3.4.

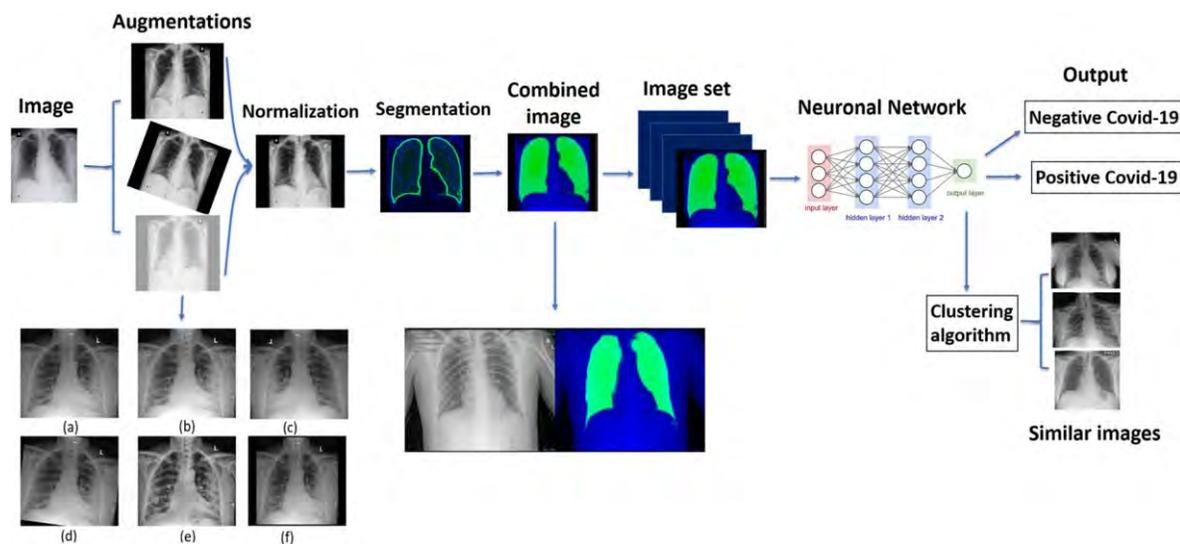


Figura 3. 4. Descripción general modelo propuesto (Keidar, et al., 2021).

## Un modelo de aprendizaje profundo impulsado por la radiomía para COVID-19 y clasificación de la neumonía no COVID-19 mediante imágenes de radiografías de tórax (Hu, et al., 2021)

El estudio propone un modelo de aprendizaje profundo basado en VGG-16 para detectar neumonía causada por COVID-19 o no COVID-19 en radiografías de tórax, utilizando análisis radiológico para mejorar el rendimiento. Un núcleo deslizante 2D extrae características representadas como mapas de características.

Se comparó con un modelo experimental entrenado con 812 radiografías (262 COVID-19, 288 neumonía no COVID-19, 262 sanos), dividiendo los datos en 649 para entrenamiento y 163 para pruebas. Se puede observar el modelo desarrollado en la Figura 3.5. El modelo experimental logró sensibilidad del 90% y 78%, especificidad del 94% y 94%, precisión del 93% y 89% y ROC AUC de 96% y 92%. Al integrar

características radiómicas como entropía y énfasis a corto plazo, el modelo propuesto mejoró significativamente: sensibilidad del 95% y 85%, especificidad del 97% y 96%, precisión del 97% y 93% y ROC AUC de 99% y 97%.

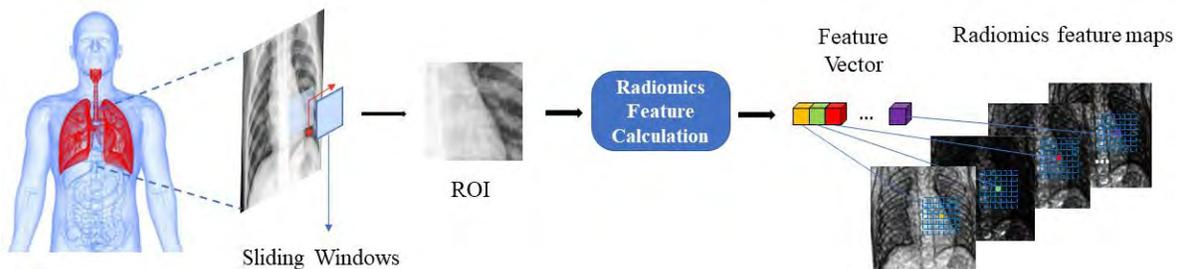


Figura 3. 5. Flujo de trabajo de la estimación del mapa de características radiómicas (Hu, et al., 2021).

### Detección de COVID-19 utilizando un algoritmo de aprendizaje profundo en imágenes de tórax (Akter, et al., 2021)

Este estudio propone un método basado en aprendizaje profundo para detectar COVID-19 a partir de radiografías de tórax. Utilizando un conjunto inicial de 3,616 imágenes COVID-19 y 10,192 imágenes sanas. Las imágenes fueron preprocesadas con NCLAHE y normalizadas antes de entrenar 11 modelos de redes neuronales convolucionales (VGG-16, VGG-19, MobileNetV2, InceptionV3, NFNet, ResNet50, ResNet101, DenseNet, EfficientNetB7, AlexNet y GoogLeNet). El modelo MobileNetV2 modificado destacó por su mayor precisión, logrando un 98% en la clasificación de COVID-19 y radiografías sanas. MobileNetV2 preentrenado obtuvo el 97%. En la figura 3.6, se observa el diagrama de bloques del modelo.

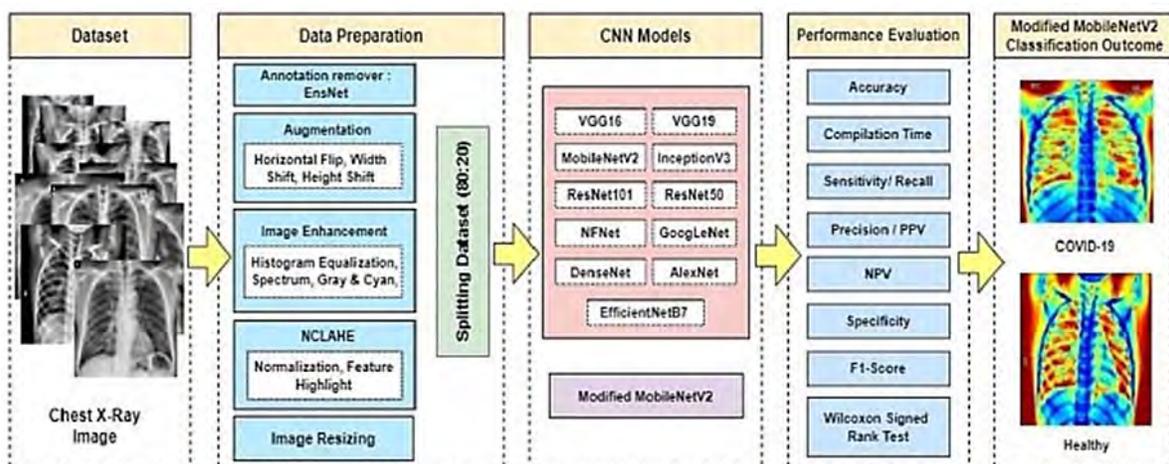


Figura 3. 6. Diagrama de bloques del modelo propuesto (Akter, et al., 2021).

## Mejora del rendimiento de la CNN para predecir la probabilidad de COVID-19 utilizando imágenes de radiografías de tórax con algoritmos de preprocesamiento (Heidari, et al., 2020)

Este estudio desarrolló un modelo con la red neuronal VGG-16 para clasificar radiografías de tórax en tres categorías: neumonía por COVID-19, neumonía no COVID-19 y casos normales. Aplicó un preprocesamiento que incluye ecualización del histograma y un filtro bilateral para mejorar las imágenes, logrando una pseudoimagen en color para el modelo. Con un conjunto de 8,474 imágenes, el modelo alcanzó una precisión del 94.5%, sensibilidad del 98.4% y especificidad del 98.0% en la detección de COVID-19. Sin el preprocesamiento, la precisión bajó al 88%, subrayando su relevancia para el desempeño del modelo. En la Figura 3.7, se puede observar el modelo propuesto.

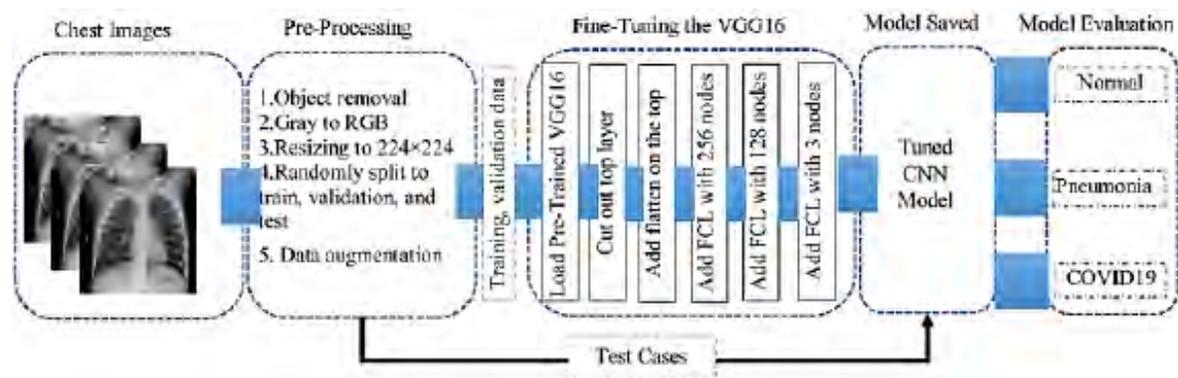


Figura 3. 7. Modelo propuesto (Heidari, et al., 2020).

## Un enfoque de aprendizaje profundo utilizando técnicas eficaces de preprocesamiento para detectar COVID-19 a partir de imágenes de tomografía computarizada y radiografías de tórax (Ahamed, et al., 2021)

Este estudio desarrolló un modelo basado en la arquitectura ResNet50V2 para detectar COVID-19, utilizando un conjunto de imágenes de tomografía computarizada y radiografías de tórax. Se aplicaron técnicas de procesamiento de imágenes, como recorte y filtros de nitidez Laplacianos, para resaltar bordes y mejorar las características visuales antes del entrenamiento. En la Figura 3.8, se puede observar el diagrama del modelo propuesto. El modelo alcanzó una precisión de: 96.45% para cuatro clases (COVID-19, normal, neumonía viral y bacteriana) usando radiografías. 97.24% para tres clases (COVID-19, normal y neumonía bacteriana). 98.95% para dos clases (COVID-19 y neumonía viral). 99.01% para tres clases (COVID-19, normal y

neumonía) con tomografías. 99.99% para dos clases (normal y COVID-19) con tomografías. En la Figura 3.8, se puede observar la arquitectura del modelo propuesto.

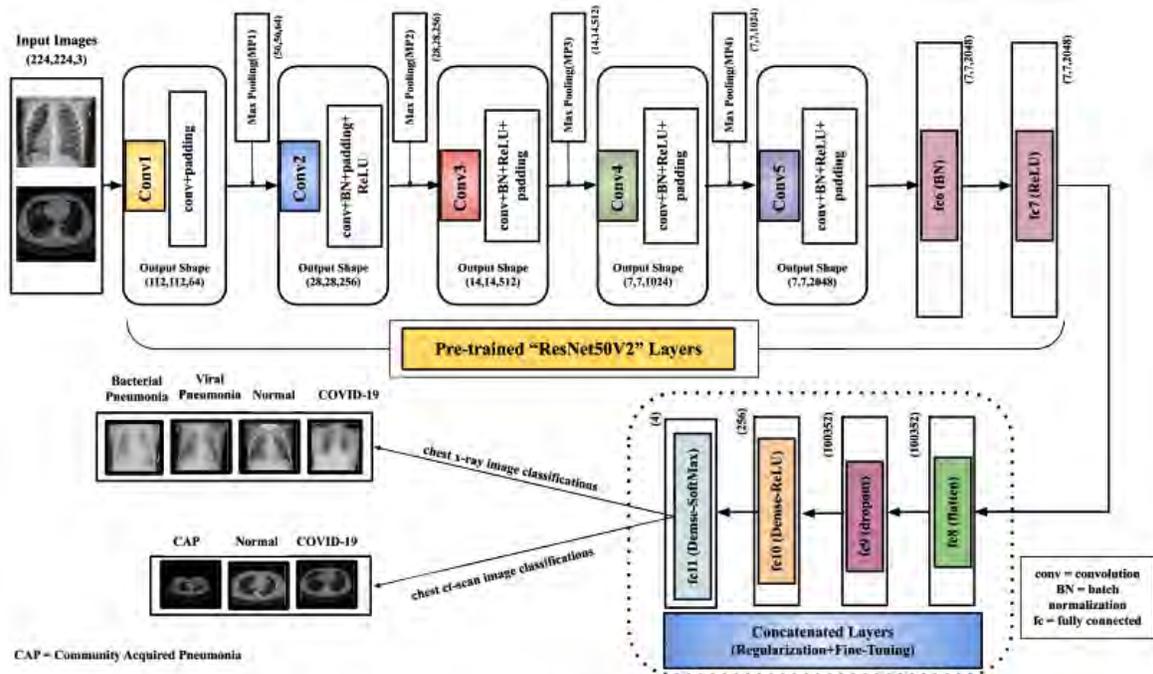
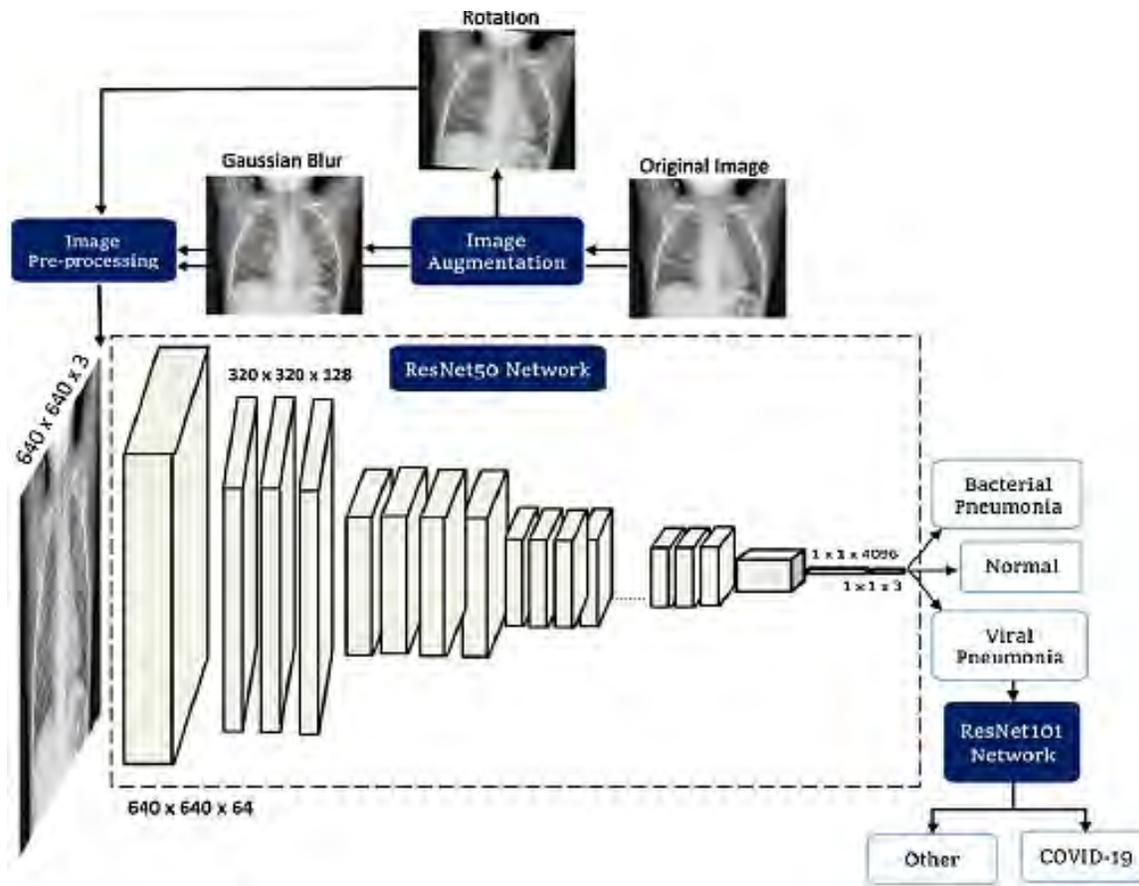


Figura 3. 8. Arquitectura del modelo propuesto (Ahamed, et al., 2021).

## Un enfoque de aprendizaje profundo para detectar COVID-19 con imágenes de radiografías de tórax (Jain, et al., 2020)

El estudio propone un modelo de detección de COVID-19 en radiografías de tórax, implementado en cuatro fases: aumento de datos, preprocesamiento, y una red profunda en dos etapas. A partir de un conjunto inicial de 1,215 imágenes, se aumentó a 1,832 mediante técnicas de aumento de datos para evitar sobreajuste y mejorar la generalización. El modelo utiliza preprocesamiento con desenfoque gaussiano (núcleo  $5 \times 5$ ) para suavizar imágenes y eliminar componentes de alta frecuencia, incorporando estas imágenes en el entrenamiento. Obtuvo una exactitud de clasificación del 97.77%, recuperación del 97.14% y precisión del 97.14% en la detección de COVID-19. En la Figura 3.9, se puede observar el diagrama de bloques sistemático del método propuesto.



**Figura 3. 9.** Diagrama de bloques sistemático del método propuesto para identificar la presencia del virus COVID-19 implementando radiografías de tórax (Jain, et al., 2020).

### **Exploración del efecto de las técnicas de mejora de la imagen en la detección de COVID-19 mediante imágenes de radiografías de tórax (Rahman., et al 2021)**

Este estudio propuso una arquitectura U-Net para segmentar pulmones en radiografías de tórax, utilizando las imágenes segmentadas para entrenar redes neuronales como ResNet18, ResNet50, ResNet101, InceptionV3, DenseNet201 y ChexNet, preentrenadas con ImageNet. Además, implementó cinco técnicas de mejora de imágenes: ecualización del histograma, CLAHE, inversión de imagen, corrección gamma y mejora de contraste equilibrado (BCET).

Se evaluaron 18,479 radiografías de tórax (8,851 normales, 6,012 con infecciones pulmonares no COVID-19 y 3,616 con COVID-19). Sin segmentación, los modelos lograron una exactitud, precisión y sensibilidad del 96.29%, mientras que, con segmentación, estos valores fueron del 95.11%, 94.55% y 94.56%. ChexNet con mejora gamma obtuvo el mejor rendimiento sin segmentación, mientras que DenseNet201 con

mejora gamma destacó para imágenes segmentadas. En la Figura 3.10 se puede observar el modelo propuesto.

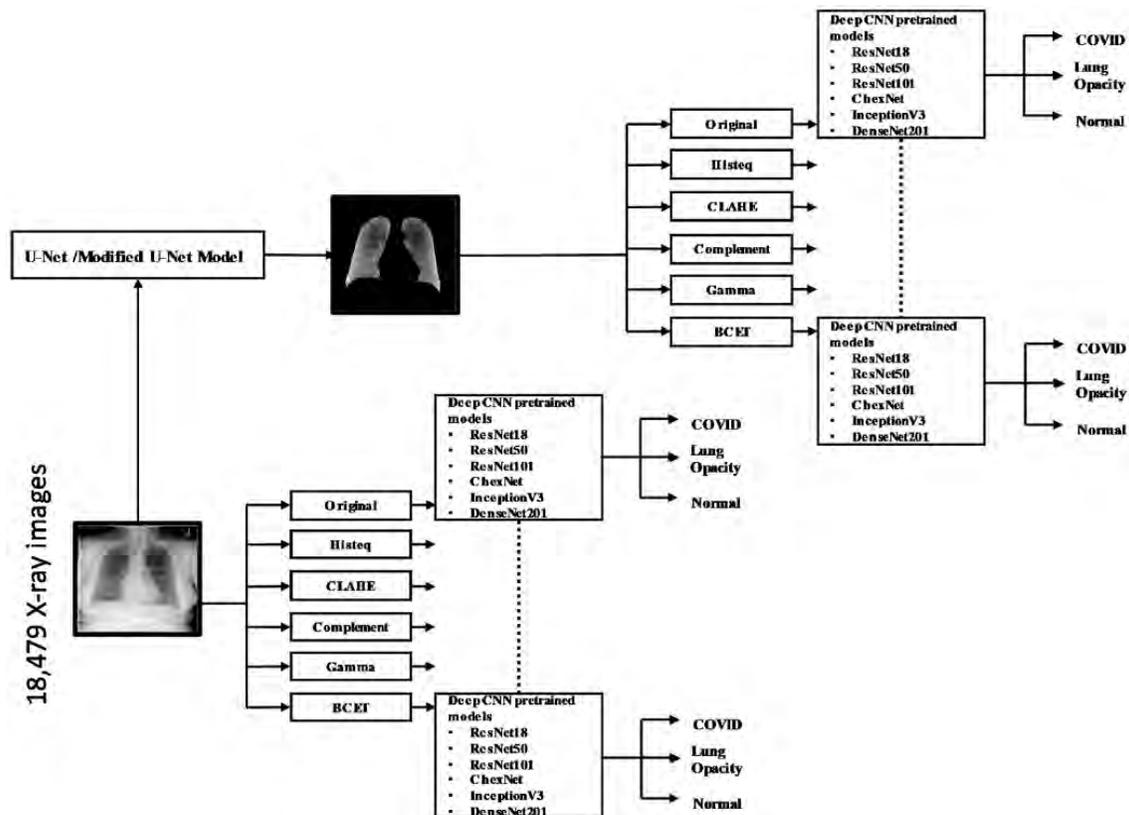


Figura 3. 10. Diagrama de bloques de la metodología propuesta (Rahman., et al 2021).

### 3.2.2 Arquitectura de red neuronal convolucional

#### TLCoV-Un modelo automatizado de cribado de COVID-19 utilizando aprendizaje por transferencia a partir de imágenes de radiografías de tórax (Das., et al, 2021)

Este estudio presenta un modelo automatizado para detectar COVID-19 en radiografías de tórax, clasificándolas como positivo a COVID-19, neumonía por otras infecciones o sin infección. Se usaron tres esquemas de aprendizaje profundo: una red neuronal convolucional estándar, VGG-16 y ResNet-50, con un conjunto de datos de Kaggle compuesto por 2,905 imágenes (219 COVID-19, 1,345 neumonía viral, 1,341 sin infección). Las imágenes se redimensionaron a  $224 \times 224$  píxeles, dividiéndose en 80% para entrenamiento y 20% para pruebas. El modelo basado en VGG-16 obtuvo el mejor desempeño, con una exactitud del 97.67%, precisión del 96.65%, sensibilidad del 96.54% y Valor-F1 del 96.59%. Observar el diagrama de flujo de la metodología en la Figura 3.11.

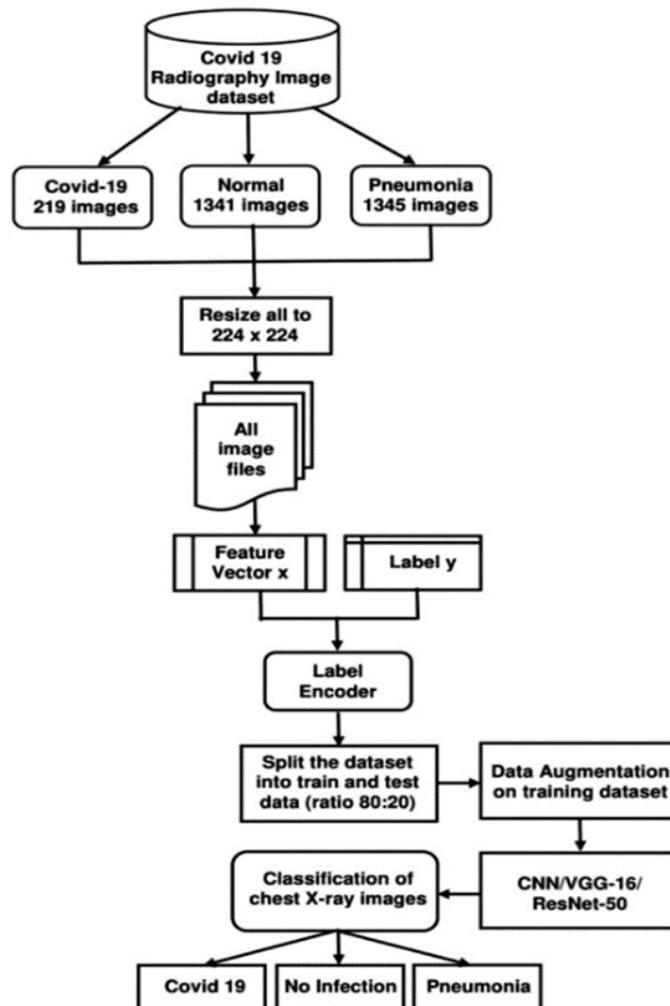


Figura 3. 11. Diagrama de flujo de la metodología del sistema (Das., et al, 2021).

### COVIDetectioNet: sistema de diagnóstico COVID-19 basado en imágenes de radiografías de tórax utilizando características seleccionadas de un conjunto de características profundas previamente aprendidas (Turkoglu, 2020)

Este estudio desarrolló COVIDetectioNet (se puede observar en la Figura 3.12), un sistema para diagnosticar COVID-19 mediante características seleccionadas de una red neuronal convolucional AlexNet preentrenada y usando aprendizaje por transferencia. AlexNet, con una arquitectura de 25 capas, incluye cinco capas de convolución, tres max-pool, tres totalmente conectadas, dos *dropout* y una capa *softmax*. Las características más relevantes se seleccionaron con el algoritmo Relief y se clasificaron utilizando una máquina de soporte vectorial (SVM). El modelo se entrenó con 6,092 radiografías de tórax clasificadas como Normal, COVID-19 y Neumonía provenientes de conjuntos de datos públicos. COVIDetectioNet alcanzó una precisión del 99.18%.

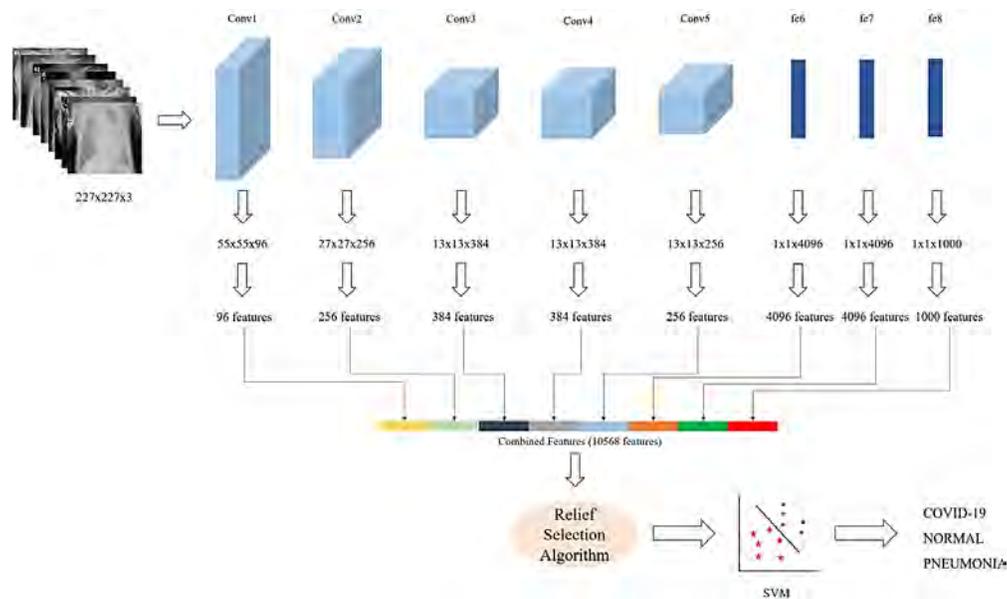


Figura 3. 12. Arquitectura del modelo propuesto COVIDetectionNet (Turkoglu, 2020).

## Detección automatizada de casos de COVID-19 utilizando redes neuronales profundas con imágenes de radiografías de tórax (Ozturk., et al 2020)

El trabajo propuesto tiene como objetivo el diagnóstico preciso para la clasificación binaria considerando como clases COVID-19 y sin hallazgos, presentando una precisión en la clasificación del 98.08% para las clases binarias; en la clasificación de clases múltiples COVID-19, sin hallazgos y neumonía se obtuvo un 87.02% de precisión.

En este modelo se implementó la red neuronal convolucional DarkNet como clasificador, la arquitectura de este modelo se conforma con 17 capas convolucionales y se introdujeron diferentes filtros en cada capa. El modelo propuesto está desarrollado para proporcionar diagnósticos precisos para la clasificación binaria y clasificación de múltiples clases. Arquitectura de la metodología propuesta en la Figura 3.13.

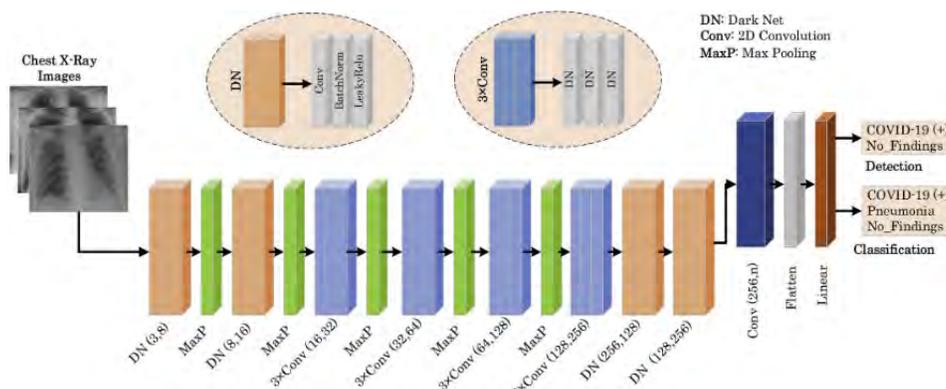


Figura 3. 13. Arquitectura del modelo propuesto (Ozturk., et al 2020).

## Una red neuronal convolucional profunda modificada para detectar COVID-19 y neumonía a partir de imágenes de radiografías de tórax basada en la concatenación de Xception y ResNet50V2 (Rahimzadeh., et al 2020)

Este estudio propone un modelo basado en la combinación de las redes neuronales convolucionales Xception y ResNet50V2 para clasificar radiografías de tórax en tres clases: normal, neumonía y COVID-19. Se utilizaron dos conjuntos de datos abiertos, con un total de 11,302 imágenes (4,420 de neumonía, 6,851 normales y 180 de COVID-19), aplicando técnicas de entrenamiento para abordar el desequilibrio de datos debido al menor número de casos de COVID-19. El modelo combina características extraídas por ambas redes para lograr resultados más robustos. En la evaluación, se obtuvo una exactitud media del 99.5% para la detección de COVID-19 y una exactitud global del 91.4% para todas las clases. Arquitectura de la metodología propuesta en la Figura 3.14.

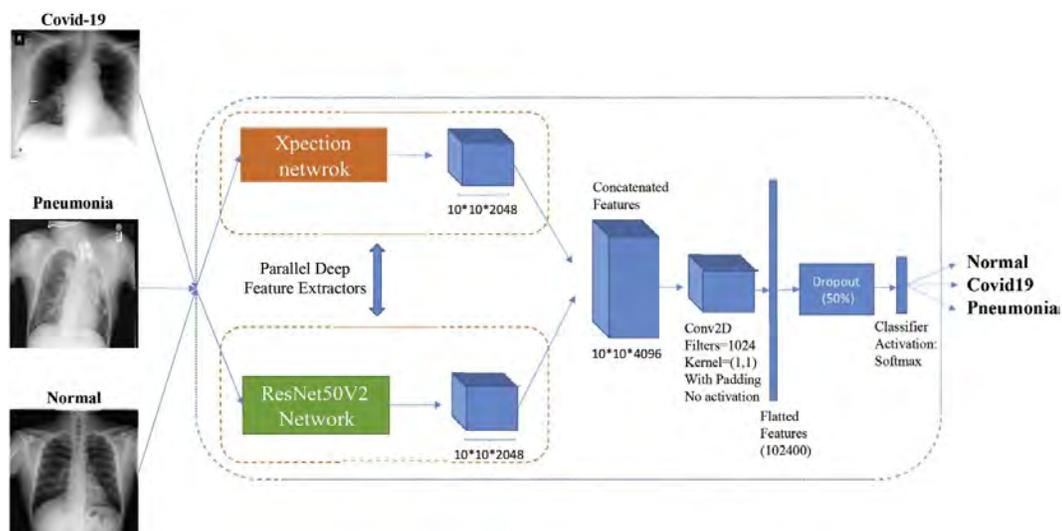


Figura 3. 14. Arquitectura del modelo propuesto (Rahimzadeh., et al 2020).

## Deep-chest: Modelo de aprendizaje profundo multclasificación para el diagnóstico de enfermedades torácicas COVID-19, neumonía y cáncer de pulmón (Ibrahim., et al 2021).

Esta investigación aborda el riesgo de diagnosticar erróneamente COVID-19 como neumonía o cáncer pulmonar a partir de imágenes torácicas, lo que puede afectar el tratamiento del paciente. Se propone un modelo de aprendizaje profundo para la multclasificación de estas patologías, utilizando radiografías y tomografías computarizadas. Se aumentó un conjunto inicial de 33,676 imágenes a 75,000 mediante técnicas de procesamiento avanzado. Se evaluaron diversas arquitecturas, destacando el modelo VGG-19 + CNN, que obtuvo un desempeño superior con métricas como

98.05% de exactitud, 99.50% de especificidad y 99.66% de área bajo la curva, entre otras. Se puede observar el modelo desarrollado en la Figura 3.15.

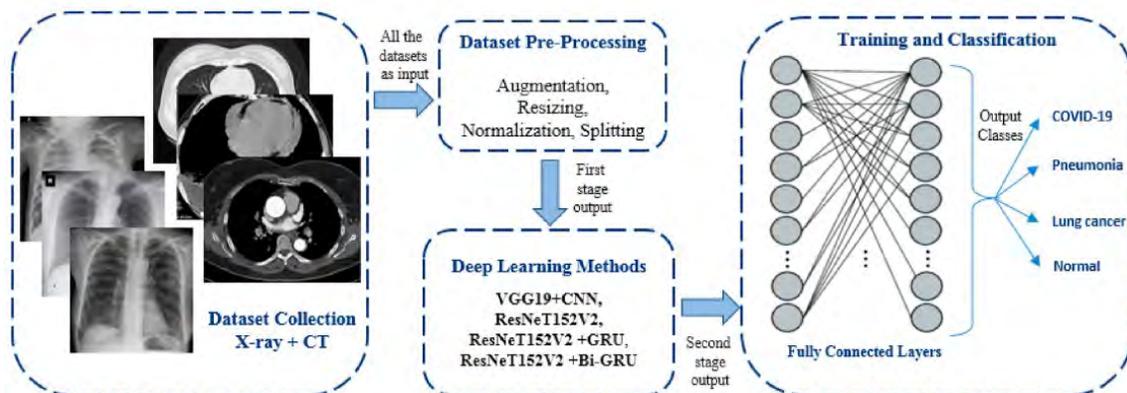


Figura 3. 15. Diagrama de bloques del modelo propuesto de clasificación (Ibrahim., et al 2021).

### Detección automática de Coronavirus (COVID-19) a partir de imágenes de TC de tórax utilizando VGG-16 Basado en aprendizaje profundo (Abdar., et al 2020)

Este estudio propone un modelo basado en redes neuronales convolucionales para clasificar casos de COVID-19 confirmados y sanos a partir de 10,979 tomografías computarizadas de tórax. Se usaron 1,936 imágenes de casos confirmados y 1,735 de sujetos sanos para el entrenamiento, aplicando técnicas de preprocesamiento como la transformación a unidades *Hounsfield*, segmentación pulmonar y mejora de contraste. El modelo elegido fue VGG-16 por su simplicidad, obteniendo una precisión del 89.78%, sensibilidad del 91.50%, especificidad del 88.66%, Valor-F1 de 90.63% y exactitud del 90.14%. Se destacó el uso de mapas de calor para identificar áreas de anomalías. Se puede observar el modelo desarrollado en la Figura 3.16.

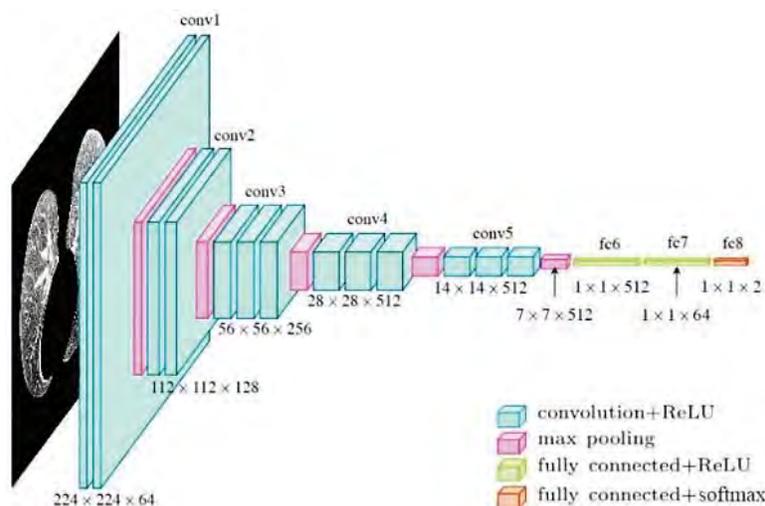


Figura 3. 16. Arquitectura del modelo que tiene como base la red VGG-16 (Abdar., et al 2020).

### **3.3. Discusión del estado del arte**

El estado del arte fue dividido en 2 núcleos temáticos; los trabajos que implementan técnicas de preprocesamiento de imágenes y las cuales permiten destacar las características, refiriéndose a las técnicas de modificación de las redes neuronales convolucionales.

Sobre los trabajos de investigación revisados se consideraron los siguientes aspectos, publicaciones, objetivo, clases de patologías, conjunto de imágenes, características de los modelos, técnicas de preprocesamiento, técnica de clasificación y métricas de evaluación.

#### **3.3.1. Hallazgos sobre la implementación de diferentes técnicas de preprocesamiento**

Entre las técnicas comúnmente implementadas por los modelos analizados destacan: la técnica de filtrados Ecuilización del Histograma (HE), Mejora de Contraste Equilibrado (BCET), Ecuilización Adaptativa del Histograma Limitada por el Contraste (CLAHE), NCLAHE y Corrección Gamma; técnicas de preprocesamiento para el aumento de datos, por ejemplo: técnicas de modificación del brillo. Entre los hallazgos obtenidos de la revisión se observa que dichas técnicas de preprocesamiento ayudan a mejorar los resultados en la experimentación de los modelos en la literatura, además, logran resaltar las características presentes en las radiografías de tórax, principalmente en modelos donde los conjuntos de datos eran desbalanceados o reducidos: estos modelos pueden observarse en el Tabla 3.1.

#### **3.3.2. Hallazgos sobre la arquitectura de la Red Neuronal Convolutacional**

En esta sección se destacan los hallazgos logrados al analizar los distintos modelos de detección de COVID-19, tanto para clasificación binaria y multiclase, donde se incluyen distintas patologías respiratorias. Se demuestra entre las arquitecturas de red más implementadas en estos trabajos tenemos las VGG, Inception, DenseNet, ResNet, Xception, MobileNet, DarkNet, y otros modelos de redes neuronales convolucionales; además, en conjunto se ha implementado diferentes técnicas de clasificación entre clases. En el Tabla 3.2, se pueden observar los modelos de los cuales se obtuvieron estos hallazgos.

Tabla 3.1. Implementación de diferentes técnicas de preprocesamiento.

Publicación	Objetivo	Clases de patología	Conjunto de imágenes	Características del modelo	Tratamiento de las imágenes	Resultados
Gupta, et al., 2020	Sistema propuesto que implementa los modelos preentrenados y afinados.	Primer grupo de clases: COVID-19, Neumonía y Normal. Segundo grupo de clases: COVID-19 y No COVID-19.	<ul style="list-style-type: none"> <li>Conjunto: 361 de la clase COVID-19, 1341 de Normal y 1345 de Neumonía.</li> <li>Muestreo: 361 imágenes de COVID-19 y 365 de Normal, 362 de clase Neumonía.</li> </ul>	Modelos pre-entrenados y afinados: ResNet101, Xception, InceptionV3, MobileNetV2, NASNet	La técnica de preprocesamiento de mejora de la imagen de color difuso de y la técnica de reconstrucción de imágenes apilamiento.	Clasificación binaria: <ul style="list-style-type: none"> <li>Exactitud del 99.53%</li> <li>Precisión del 100%</li> <li>Sensibilidad del 99%</li> </ul> Clasificación de 3 clases: <ul style="list-style-type: none"> <li>Exactitud del 99.08%</li> <li>Promedio de sensibilidad del 99%</li> <li>Valor-F1 del 99%</li> <li>Precisión del 99%</li> </ul>
Singh, et al., 2021	Un modelo de aprendizaje profundo que implementa radiografías de tórax para la clasificación precoz de pacientes con COVID-19.	<ul style="list-style-type: none"> <li>COVID-19</li> <li>Neumonía</li> </ul>	El conjunto de datos del modelo propuesto dispone de 572 muestras de COVID-19, 6,041 pertenecientes a neumonía y 8,851 normal.	Conjunto apilado modificado que integra VGG-16, ResNet-50, DenseNet-121 y DenseNet-169, combinado con Naive Bayes como metaaprendiz	Utilizo la técnica variante de ecualización de histograma denominada CLAHE y realiza la segmentación de la imagen con arquitectura U-Net.	Obtuvo resultados significativos, de un 98,67% de exactitud, una puntuación Kappa de 0.98 y un Valor-F1 de 100%, 98% y 98% para las clases de COVID-19, normal y neumonía, correspondiente.
Ucar, et al., 2020	Un modelo de aprendizaje profundo para la detección de COVID-19, implementando como base la red SqueezeNet.	<ul style="list-style-type: none"> <li>COVID-19</li> <li>Neumonía</li> </ul>	76 radiografías de COVID-19, 1,583 perteneciente a la clase normal y 4,295 de neumonía.	SqueezeNet es un diseño de red ligera ajustada para el diagnóstico COVID-19 con optimización bayesiana aditiva.	Aplico las técnicas de aumento a las imágenes originales y a las recortadas: ruido, corte, disminución del brillo, aumento de la luminosidad.	<ul style="list-style-type: none"> <li>Exactitud del 98.3% entre los casos de Normal, Neumonía y COVID-19</li> <li>100% para el reconocimiento único de COVID-19.</li> </ul>

**Tabla 3.1.** Implementación de diferentes técnicas de preprocesamiento (Continuación).

Publicación	Objetivo	Clases de patologías	Conjunto de imágenes	Características del modelo	Tratamiento de las imágenes	Resultados
Mostafiz, et al., 2020	Modelo que implementa redes neuronales convolucionales profundas híbridas y la transformación de wavelet (DWT).	<ul style="list-style-type: none"> <li>■ COVID-19</li> <li>■ Normal</li> </ul>	790 de Covid-19, 1,215 de neumonía viral, 1,304 de neumonía bacteriana y 1,500 normales, después del aumento de datos	Las características de ambos métodos (red neuronal convolucional y DWT) generan un vector de fusión, que está optimizado a través de técnicas mRMR y RFE.	Se utiliza la técnica CLAHE y realiza la segmentación de la imagen implementando la arquitectura U-Net.	Precisión general superior al 98.5%.
Keidar, et al., 2021	Modelo de aprendizaje profundo para la detección de COVID-19 mediante radiografía de tórax.	<ul style="list-style-type: none"> <li>■ COVID-19</li> <li>■ NO COVID-19</li> </ul>	<ul style="list-style-type: none"> <li>■ COVID-19: 1,384</li> <li>■ NO COVID-19: 1,024</li> </ul>	El clasificador consta de un conjunto de redes neuronales profundas, ReNet34, ReNet50, ReNet152 y VGG-16	<ul style="list-style-type: none"> <li>■ Brillo</li> <li>■ Giro horizontal</li> <li>■ Rotación de 7 grados</li> <li>■ Transformación CLAHE</li> <li>■ Escala</li> <li>■ Normalización</li> <li>■ Segmentación</li> </ul>	<ul style="list-style-type: none"> <li>■ Exactitud del 90.3%</li> <li>■ Especificidad del 90%</li> <li>■ Sensibilidad del 90.5%</li> <li>■ AUC de la curva ROC es 0.96.</li> </ul>
Hu, et al., 2021	Modelo de aprendizaje profundo que integre el análisis radiomica para mejorar el rendimiento de Detección de neumonía COVID-19 y no COVID-19 mediante imagen de radiografías de tórax.	<ul style="list-style-type: none"> <li>■ COVID-19</li> <li>■ No COVID-19</li> <li>■ Casos sanos</li> </ul>	<ul style="list-style-type: none"> <li>■ COVID-19: 262</li> <li>■ NO COVID-19: 288</li> <li>■ Casos sanos: 262</li> </ul>	Basado en una arquitectura VGG-16 preentrenada.	Técnica de Radiomica.	<ul style="list-style-type: none"> <li>■ COVID-19 y noCOVID-19: Sensibilidad 0.95±0.04, 0.85±0.04;</li> <li>■ Especificidad 0.97±0.02, 0.96±0.02;</li> <li>■ Precisión 0.97±0.02, 0.93±0.02;</li> <li>■ ROC AUC 0.99±0.01, 0.97±0.02.</li> </ul>

Tabla 3.1. Implementación de diferentes técnicas de preprocesamiento (Continuación).

Publicación	Objetivo	Clases de patologías	Conjunto de imágenes	Características del modelo	Tratamiento de las imágenes	Resultados
Akter, et al., 2021	Modelo de clasificación basado en aprendizaje profundo, basado en una red neuronal convolucional, que demuestra una tasa de detección rápida para COVID-19.	<ul style="list-style-type: none"> <li>▪ COVID-19</li> <li>▪ Sano</li> </ul>	<ul style="list-style-type: none"> <li>▪ COVID-19: 3,616</li> <li>▪ Sanos: 10,192</li> </ul>	<ul style="list-style-type: none"> <li>▪ Implemento modelos preentrenados; VGG-16, VGG-19, MobileNetV2, InceptionV3, NFNNet, ResNet50, ResNet101, DenseNet, EfficientNetB7, AlexNet y GoogLeNet.</li> </ul>	<ul style="list-style-type: none"> <li>▪ Ecuación de histogramas, espectro, escala de grises, cian y se normalizó con NCLAHE.</li> </ul>	<ul style="list-style-type: none"> <li>▪ MobileNetV2 obtuvo 98% en exactitud al clasificar entre COVID-19 y Sano.</li> </ul>
Heidari, et al., 2020	Detectar y clasificar imágenes en 3 clases, a saber, neumonía infectada por COVID-19, la otra neumonía no infectada por COVID-19 adquirida en la comunidad y casos normales (sin neumonía).	<ul style="list-style-type: none"> <li>▪ COVID-19: 415</li> <li>▪ Neumonía: 5,179</li> <li>▪ Normal: 2,880</li> </ul>	<ul style="list-style-type: none"> <li>▪ Neumonía infectada por COVID-19</li> <li>▪ Neumonía no infectada por COVID-19</li> <li>▪ COVID-19 adquirida en la comunidad</li> <li>▪ Casos normales</li> </ul>	<ul style="list-style-type: none"> <li>▪ Modelo VGG-16, que se entrenó previamente en ImageNet</li> <li>▪ Large Scale Visual Recognition Challenge (ILSVRC).</li> </ul>	<ul style="list-style-type: none"> <li>▪ Algoritmo de ecuación de histograma</li> <li>▪ Filtro de paso bajo bilateral</li> <li>▪ Una imagen de Pseudo color</li> </ul>	<ul style="list-style-type: none"> <li>▪ Exactitud general del 94.5% al clasificar 3 clases;</li> <li>▪ Sensibilidad del 98.4% y</li> <li>▪ Especificidad del 98% en la clasificación de casos con y sin infección por COVID-19.</li> <li>▪ Sin utilizar dos pasos de preprocesamiento, produce una exactitud de clasificación del 88%.</li> </ul>
Ahamed, et al., 2021	Modelo de detección de COVID-19 basado en aprendizaje profundo entrenado con imágenes de tomografías computarizadas y radiografías de tórax.	<ul style="list-style-type: none"> <li>▪ COVID-19: 1,143</li> <li>▪ Normal: 1,150</li> <li>▪ Neumonía viral: 1,150</li> <li>▪ Neumonía bacteriana: 1,150</li> </ul>	<ul style="list-style-type: none"> <li>▪ Radiografía</li> <li>▪ COVID-19</li> <li>▪ Normal</li> <li>▪ Neumonía viral</li> <li>▪ Neumonía bacteriana</li> </ul>	<ul style="list-style-type: none"> <li>▪ Arquitectura ResNet50V2 modificada.</li> </ul>	<ul style="list-style-type: none"> <li>▪ Filtro Laplaciano</li> <li>▪ Recorte</li> <li>▪ Aumento de datos</li> <li>▪ Técnica Sharpaned</li> </ul>	<ul style="list-style-type: none"> <li>▪ Obtuvo una exactitud del 96.452% en cuatro clases,</li> <li>▪ 97.242% en tres clases,</li> <li>▪ 98.954% en tres clases, implementando radiografías;</li> <li>▪ Exactitud del 99.012% tres clases, 99.99% en dos clases, mediante tomografía.</li> </ul>

**Tabla 3.1.** Implementación de diferentes técnicas de preprocesamiento (Continuación).

Publicación	Objetivo	Clases de patologías	Conjunto de imágenes	Características del modelo	Tratamiento de las imágenes	Resultados
Jain, et al., 2020	Herramienta de diagnóstico alternativa para detectar casos de COVID-19 utilizando los recursos disponibles y técnicas avanzadas de aprendizaje profundo.	<ul style="list-style-type: none"> <li>▪ COVID-19</li> <li>▪ Otro</li> </ul>	<ul style="list-style-type: none"> <li>▪ COVID-19: 250</li> <li>▪ Sanos: 315</li> <li>▪ Neumonía bacteriana: 300</li> <li>▪ Neumonía viral: 350</li> </ul>	ResNet-50 clasifica neumonías virales, bacterianas y casos normales, mientras que ResNet-101 detecta COVID-19 en neumonías virales.	<ul style="list-style-type: none"> <li>▪ Rotación</li> <li>▪ Filtro desenfoque Gaussiano</li> </ul>	Exactitud de clasificación del 97.77%, Sensibilidad del 97.14%, Precisión del 97.14%
Rahman, et al., 2021	Detección de COVID-19 mediante imágenes de radiografías de tórax.	<ul style="list-style-type: none"> <li>▪ COVID-19</li> <li>▪ Infección pulmonar no COVID-19</li> </ul>	Conjunto de datos de 18,479: radiografías: 8,851 normales, 6,012 con infecciones pulmonares no COVID-19 y 3,616 con COVID-19, todas con máscaras pulmonares de verdad.	<ul style="list-style-type: none"> <li>▪ Nueva arquitectura U-Net</li> <li>▪ ResNet18</li> <li>▪ ResNet50</li> <li>▪ ResNet101</li> <li>▪ InceptionV3</li> <li>▪ DenseNet20</li> <li>▪ ChexNet</li> </ul>	<ul style="list-style-type: none"> <li>▪ HE</li> <li>▪ CLAHE</li> <li>▪ Imagen invertida</li> <li>▪ Corrección gamma</li> <li>▪ BCET</li> <li>▪ Redimensionar tamaños para las entradas de las redes y aumento de datos por rotación.</li> </ul>	El método propuesto alcanzó una exactitud del 95.11%, precisión del 94.55%, recuerdo del 94.56%, alor-F1 del 94.53% y especificidad del 95.59% en la evaluación de radiografías de tórax segmentadas.

Tabla 3.2. Arquitectura de Red Neuronal Convocional.

Publicación	Objetivo	Clases de patología	Conjunto de imágenes	Características del modelo	Tratamiento de las imágenes	Resultados
Das., et al, 2021	Clasificándolas como positivo a COVID-19, neumonía por otras infecciones o sin infección	<ul style="list-style-type: none"> <li>▪ COVID-19</li> <li>▪ Neumonía viral</li> <li>▪ Sin infección</li> </ul>	2,905 imágenes (219 COVID-19, 1,345 neumonía viral, 1,341 sin infección)	<ul style="list-style-type: none"> <li>▪ VGG-16</li> <li>▪ ResNet-50</li> </ul>	Las imágenes se redimensionaron a 224×224 píxeles, dividiéndose en 80% para entrenamiento y 20% para pruebas	El modelo basado en VGG-16 obtuvo el mejor desempeño, con una exactitud del 97.67%, precisión del 96.65%, sensibilidad del 96.54% y Valor-F1 del 96.59%.
Turkoglu, 2020	Un sistema que utiliza características seleccionadas de una combinación de características profundas para el diagnóstico de COVID-19.	<ul style="list-style-type: none"> <li>▪ COVID-19</li> <li>▪ Neumonía</li> </ul>	Recolecto un total de 6,092 imágenes de radiografías de tórax, clasificadas como Normal (saludable), COVID-19 y Neumonía.	Utilizó AlexNet entrenada, se seleccionaron características con el algoritmo Relief y se clasificaron con una máquina de soporte vectorial.	No implementa técnicas de preprocesamiento.	En los resultados experimentales obtuvo una precisión del 99.18%.
Ozturk, et al., 2020	El diagnóstico preciso para la clasificación binaria considerando como clases COVID-19 y normal.	<ul style="list-style-type: none"> <li>▪ COVID-19</li> <li>▪ Neumonía</li> </ul>	<ul style="list-style-type: none"> <li>▪ 127 radiografías diagnosticadas con COVID-19.</li> <li>▪ 500 radiografía normales.</li> <li>▪ 500 radiografía con neumonía</li> </ul>	Implementó la arquitectura DarkNet con 17 capas convolucionales.	Normalización por lotes para estandarizar las entradas, logrando reducir el tiempo de entrenamiento y aumentar la estabilidad del modelo.	Para la clasificación binaria entre COVID-19 y sin hallazgos, se obtuvo una precisión del 98.08%. En la clasificación de clases múltiples (COVID-19, sin hallazgos y neumonía), la precisión fue del 87.02%.

**Tabla 3.2.** Arquitectura de Red Neuronal Convolutiva (continuación).

Publicación	Objetivo	Clases de patologías	Conjunto de imágenes	Características del modelo	Tratamiento de las imágenes	Resultados
Rahimzadeh, et al., 2020	Entrenamiento de redes neuronales convolucionales profundas para clasificar radiografías de tórax en tres clases: normal, neumonía y COVID-19.	<ul style="list-style-type: none"> <li>▪ COVID-19</li> <li>▪ Neumonía</li> </ul>	Se utilizó 11,302, perteneciendo 180 a COVID-19, 4,420 a neumonía y normal 8,851.	Concatenar las redes Xception y ResNet50V2, extrayendo sus características y conectándolas a una capa convolutiva para el clasificador.	Las imágenes de entrada del modelo previamente redimensionadas a 300x300.	La exactitud media de la red propuesta para detectar los casos de COVID-19 es del 99.5%, y la exactitud media global para todas las clases es del 91.4%.
Ibrahim, et al., 2021	Diagnóstico efectivo de COVID-19 mediante radiografía de tórax y tomografía computarizada de tórax.	<ul style="list-style-type: none"> <li>▪ COVID-19</li> <li>▪ Neumonía</li> <li>▪ Cáncer pulmonar</li> </ul>	El conjunto de radiografía y tomografías de tórax, conforma, el número total de imágenes de los conjuntos de datos recopilados es de 33,676 imágenes.	Arquitecturas de aprendizaje profundo: <ul style="list-style-type: none"> <li>▪ VGG-19</li> <li>▪ ResNet152V2</li> <li>▪ ResNet152V2 + Gated Recurrent Unit (GRU)</li> <li>▪ ResNet152V2 + Bidireccional GRU (Bi-GRU)</li> </ul>	Aplicar dos técnicas de procesamiento de mejora de la imagen de color difuso y apilamiento.	Se obtuvo una exactitud del 98.05%, sensibilidad del 98.05%, precisión del 98.43%, especificidad del 99.50%, valor predictivo negativo del 99.3%, Valor-F1 del 98.24%, coeficiente de correlación de Matthew del 97.70% y área bajo la curva del 99.66%.
Abdar, et al 2020	Desarrollar un modelo de red neuronal convolutiva para la clasificación de los casos de COVID-19 de los	<ul style="list-style-type: none"> <li>▪ COVID-19</li> <li>▪ Sano</li> </ul>	Implemento 10,979 imágenes de tomografías de 131 pacientes con COVID-19, con máscaras de infección y 150 sujetos sanos.	Entreno y evaluo varias redes de aprendizaje profundo, como ResNet, Inception, VGG-16, DenseNet y Xception.	Se transformaron las intensidades a la unidad Hounsfield, se extrajo la parte pulmonar, se igualaron los histogramas y se estiró el contraste de las imágenes.	En la experimentación con imágenes de TC, se obtuvieron los siguientes resultados: precisión del 89.78%, sensibilidad del 91.50%, especificidad del 88.66%, Valor-F1 de 90.63% y exactitud del 90.14%.

## Capítulo 4

### Propuesta de solución

En este capítulo, se manifiesta la propuesta de solución, siendo este el tema principal de la investigación. Para el desarrollo la propuesta de solución se establecieron 4 módulos: adquisición y selección de conjuntos de imágenes médicas; desarrollo del repositorio de radiografías de tórax; análisis y selección de técnicas de preprocesamiento; y, análisis y selección de técnicas de clasificación, pudiendo ser observada la propuesta de solución en la Figura 4.1.

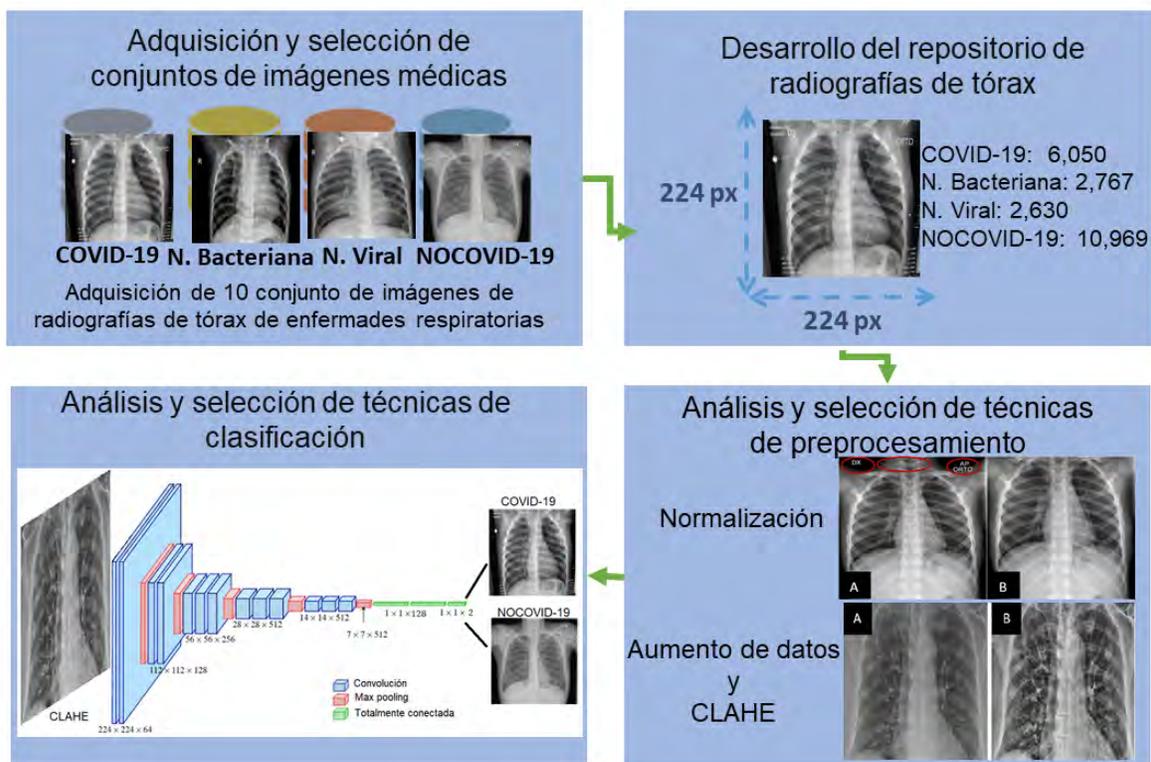


Figura 4. 1. Diagrama de bloques de la propuesta de solución.

#### 4.1 Adquisición y selección de conjuntos de imágenes médicas

En esta sección se describe el proceso de adquisición de imágenes de radiografías de tórax de pacientes confirmados con COVID-19, neumonía viral, neumonía bacteriana y NOCOVID-19 (afectación pulmonar similar a COVID-19), realizado con el objetivo de conformar un conjunto grande de radiografías de pacientes confirmados con las patologías mencionadas previamente. Esta recopilación se realizó mediante la

adquisición de 10 conjuntos de imágenes de radiografías de tórax de acceso público, desarrollados por instituciones dedicadas al estudio y análisis de imágenes médicas radiológicas, universidades, hospitales, clínicas y médicos particulares alrededor del mundo.

Estos conjuntos de imágenes se han conformado para distintos propósitos: para ser implementados en investigaciones para el desarrollo de modelos de aprendizaje profundo de prediagnóstico de COVID-19 y patologías similares, para registro de casos, académica para la instrucción para el prediagnóstico de las patologías. En la tabla 4.1; se puede observar en síntesis la información de los conjuntos de imágenes adquiridos.

**Tabla 4. 1.** Conjuntos de imágenes de datos.

Conjunto de imágenes	Características	Radiografías de tórax
Chowdhury, et al., 2020; Rahman, et al., 2021	Casos confirmados de COVID-19, normal y neumonía viral, con dimensiones de 299 × 299 en formato <i>Portable Network Graphics</i> .	COVID-19: 3,616 Neumonía Viral: 1,415 Neumonía Bacteriana: 2,760 Otras: 10,192
Rafid909, 2020	Casos de neumonía bacteriana, neumonía viral, COVID-19 y sujetos sanos. De diferentes dimensiones en formatos JPEG, JPG y PNG.	COVID-19: 790 Neumonía Bacteriana: 1,304 Neumonía Viral: 1,215 Otras: 1,500
Dadario, 2020	Casos confirmados de COVID-19, extraídas de conjuntos de imágenes de artículos y bases de datos disponibles públicamente con diferentes dimensiones y, formatos JPEG y JPG.	COVID-19: 79
Agchung, 2020	Casos confirmados de COVID-19 en formato PNG y JPG.	COVID-19: 55
Dutta, 2021	Casos de normales y COVID-19, recopilado de tres hospitales en los estados de Uttar Pradesh y Rajasthan de la India, dispone de diferentes dimensiones con formato JPG.	COVID-19: 422 Otras: 77
Khasawneh, 2021	Caso tórax recopilados de ingresos en un hospital, debido a complicaciones respiratorias ocasionadas por el COVID-19, recopilado por la Universidad de Ciencia y Tecnología. De 1024 × 851 en JPG.	COVID-19: 368
Chest Imaging, 2020	Casos confirmados con COVID-19 de un hospital es España de 50 pacientes. Con dimensiones diferentes y formato JFIF.	COVID-19: 111
Desai, et al., 2020	Casos positivos a COVID-19 en formato PNG, desarrollado por el Instituto de Investigación Traslacional de la Universidad de Arkansas para Ciencias Médicas.	COVID-19: 267

**Tabla 4. 1.** Conjuntos de imágenes de datos. (continuación).

Conjunto de imágenes	Características	Radiografías de tórax
BSTI, 2020	<i>BSTICimar UK's Imaging Cloud Technology</i> , portal en web con COVID-19 confirmado o sospechoso de COVID-19, con diferentes dimensiones en formato PNG.	COVID-19: 33
Tsai, et al., 2021	Colaboración entre la RSNA y la STR. Conformado por 1,257 radiografías de tórax, con dimensiones en $4,240 \times 3,480$ en formato PNG.	COVID-19: 1,257

## 4.2 Desarrollo del repositorio de radiografías de tórax

En el proceso de adquisición de conjuntos de imágenes de radiografías de tórax de los repositorios recolectados, se recopiló una gran cantidad de radiografías de tórax correspondientes a casos de COVID-19, en el desarrollo de los primeros modelos de prediagnóstico no se implementaban conjuntos de imágenes bastos debido a que no se disponía de estos.

El repositorio de radiografías de tórax desarrollado, demuestra ser el conjunto de imágenes de radiografías de tórax posterior anterior con mayor cantidad de imágenes de radiografías de COVID-19 que se haya realizado; en comparación con conjuntos recopilados para ser utilizados en el entrenamiento y evaluación, en modelos desarrollados para prediagnóstico de COVID-19 y otras patologías respiratorias similares que utilicen la técnica de aprendizaje profundo previamente desarrollados.

### 4.2.1 Selección de conjuntos de imágenes médicas

Después del proceso de adquisición de radiografía de tórax se procedió a la tarea de selección de las imágenes de radiografías de tórax para conformar el repositorio de imágenes, este proceso consistió en descartar imágenes mediante el cribado de las imágenes adquiridas. De esta manera se eliminaron las imágenes de radiografías de tórax que se repitieron entre conjuntos y la calidad de imagen no era factible. En la Tabla 4.2, se muestra la cantidad de radiografías de tórax seleccionadas de cada uno de los conjuntos de imágenes de acceso público que se consideraran para el desarrollo del modelo de aprendizaje profundo.

**Tabla 4. 2.** Selección de imágenes de los conjuntos de datos.

Conjunto de imágenes	Conjuntos recopilados
Chowdhury, et al., 2020; Rahman, et al., 2021	COVID-19: 3,148
	Neumonía Viral: 1,415
	Neumonía Bacteriana: 2,760
	Otras: 9,392
Rafid909, 2020	COVID-19: 638
	Neumonía Bacteriana: 1,304
	Neumonía Viral: 1,215
	Otras: 1,500
Dadario, 2020	COVID-19: 38
Agchung, 2020	COVID-19: 53
Dutta, 2021	COVID-19: 421
	Otras: 77
<u>Khasawneh, 2021</u>	COVID-19: 367
Chest Imaging, 2020	COVID-19: 106
Desai, et al., 2020	COVID-19: 244
BSTI, 2020	COVID-19: 30
Tsai, et al., 2021	COVID-19: 1,005

Al conjunto de imágenes recopiladas, se le aplicó una normalización de los datos, consistiendo en redimensionar las imágenes en una dimensión estandarizada de  $224 \times 224$  y convertirlas al formato PNG; para poder ser implementadas en el modelo propuesto. En la Tabla 4.3, se puede observar las cantidades de imágenes recopiladas para cada patología. El repositorio de imágenes de radiografías de tórax desarrollado, es de acceso libre en la plataforma de *Google Drive*, mediante el enlace, <https://acortar.link/e7hv84>, permitiendo ser implementado para futuras investigaciones.

**Tabla 4. 3.** Recopilación de radiografías de tórax por clases.

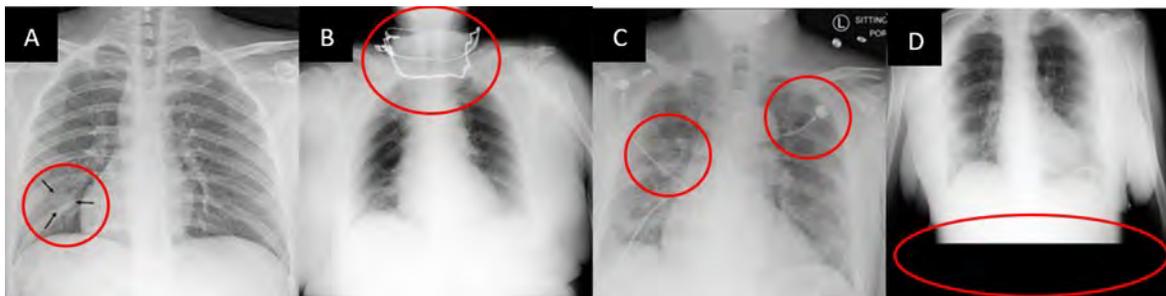
Clases de las patologías	Cantidad de radiografías de tórax
COVID-19	6,050
Neumonía Bacteriana	2,767
Neumonía Viral	2,630
NOCOVID-19 (Otras afectaciones)	10,969
Total	22,416

## 4.3 Análisis y selección de técnicas de preprocesamiento

El análisis visual de imágenes que integran el conjunto de datos muestra que algunas de las radiografías de tórax están sobreexpuestas o subexpuestas; además, algunas de las imágenes recopiladas pueden presentar ruido, afectando la comprensión de los hallazgos presentes en la imagen. Considerando lo anterior, se tuvo la necesidad de implementar técnicas de preprocesamiento para mejoras de la imagen. Varios estudios del estado del arte han demostrado que el preprocesamiento de imágenes es importante para estandarizar el conjunto de imágenes y, por lo tanto, lograr un rendimiento efectivo del modelo de aprendizaje profundo en el proceso de clasificación.

### 4.3.1 Normalización del conjunto de datos

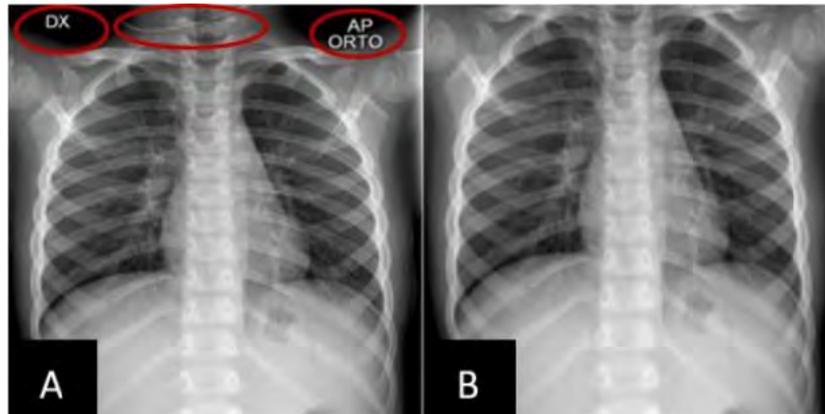
Después del proceso de cribado del conjunto de imágenes, se procedió a analizar visualmente cada una de estas, presentando en una cierta cantidad imágenes de cada clase, la presencia de diferentes tipos de dispositivos médicos, objetos personales del paciente; también en las imágenes se presentan etiquetas realizadas por el equipo captura de la radiografía o solicitada por el médico; además se encontraron imágenes que mostraban inclinación torácica del paciente durante la captura, exceso de luminosidad en ciertas regiones de la imagen y presencia de márgenes en las imágenes; en la Figura 4.2, se puede observar ejemplos de estos casos. Para poder depurar los conjuntos de imágenes de cada una de las clases se procedió a realizar la normalización del conjunto de datos, mediante el descarte de imágenes que presentaban algunas de las características mencionadas anteriormente y que no se pudieran modificar estas regiones de la imagen sin dañar la zona pulmonar de la imagen.



**Figura 4. 2.** A) Presencia de etiqueta realizada por el médico, B) Objeto personal del paciente, C) Dispositivo médico, D) Márgenes anexados en la imagen.

Consecuentemente, se procedió a realizar la normalización de las imágenes de radiografías de tórax del conjunto de imágenes recopilado que fueron modificadas; editándolas, sin dañar el área pulmonar del tórax; además, se conservaron las imágenes

que no requieran edición; en la Figura 4.3, se puede observar un ejemplo de normalización. De esta manera, se desarrolló el nuevo conjunto de imágenes normalizado registrados ante el INDAUTOR con el nombre COVID-TECNM (Reyes, et al., 2022), en la Tabla 4.4 se puede observar la cantidad de imágenes por clases de patología.



**Figura 4. 3.** A) Presencia de etiqueta realizada por el dispositivo de captura. B) Misma imagen normalizada.

**Tabla 4. 4.** Conjunto de imágenes de radiografías de tórax normalizado.

Clases de las patologías	Cantidad de radiografías de tórax	Reducción porcentual
COVID-19	3,336	44.86%
Neumonía Bacteriana	1,369	50.53%
Neumonía Viral	1,376	47.68%
NOCOVID-19 (Otras afectaciones)	3,361	69.36%
Total	8,317	62.90%

### 4.3.2 Análisis e implementación de técnicas de filtrado

Después de realizar la normalización del conjunto de imágenes se procedió a aplicar sobre este nuevo conjunto normalizado cinco técnicas de filtrado para mejorar la nitidez de la imagen seleccionadas por su desempeño observado en el estado del arte y codificadas en lenguaje Python, las cuales se mencionan a continuación.

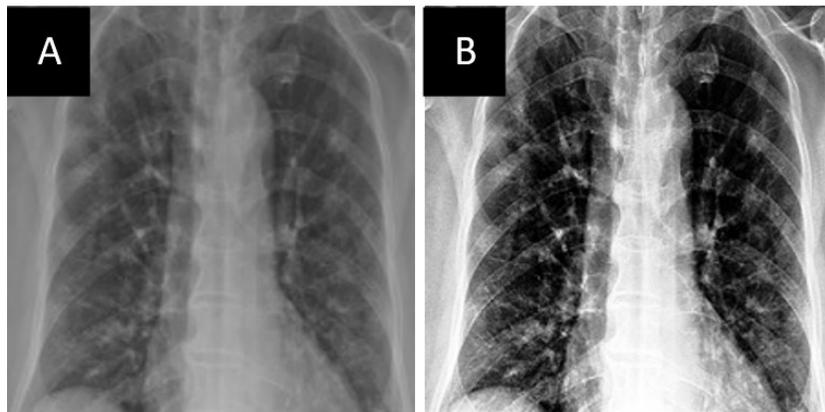
#### **Ecuación del Histograma**

Esta técnica de preprocesamiento consiste en la aplicación del filtro de ecualización del histograma (HE, siglas en inglés) al conjunto normalizado previamente, este filtro tiene como objetivo el mejorar el contraste de la imagen, implementando el método de ecualización del histograma local, mejorando eficazmente el contraste general de la imagen. El proceso de ecualización del histograma consiste en que los píxeles de la

imagen son modificados mediante una función de transformación basada en el contenido gris de la imagen; generando cambios en la distribución del histograma. La Ecuación 4.1, representa la fórmula general para calcular la ecualización de histogramas:

$$h(v) = \text{round} \left( \frac{CDF(v) - CDF_{min}}{(M \times N) - CDF_{min}} \times (L - 1) \right) \quad (4.1)$$

donde,  $CDF_{min}$  es el valor mínimo no cero de la función de distribución acumulativa de las intensidades de los píxeles,  $M \times N$  obtiene la cantidad de píxeles del mosaico elegido, donde  $M$  corresponde a la anchura,  $N$  es la altura y  $L$  al número de niveles de gris (Gan, 2020). En la Figura 4.4, se observa los resultados al utilizar el filtro en radiografías de tórax de un paciente confirmado con COVID-19 del conjunto de datos previamente normalizado.



**Figura 4. 4.** Radiografía de tórax positivo a COVID-19, A) Original. B) Radiografía aplicado filtro HE.

Su desempeño al aplicar esta técnica puede ser observado en el capítulo 5 de experimentación en las secciones 5.2.3 y 5.2.5; debido a su múltiple implementación durante los experimentos realizados.

### Técnica de mejora de contraste equilibrado

De igual manera al conjunto de imágenes normalizado se le aplicó el filtro denominado como la Técnica de mejora de contraste equilibrado (BCET, siglas en inglés), el cual permite mejorar el equilibrio del contraste al estirar o comprimir el contraste de la imagen sin cambiar el histograma de los datos de la imagen. La solución se basa en una función parabólica obtenida a partir de datos de imágenes. La forma de función parabólica general usando la coordenada  $y$  y la coordenada  $x$  en el plano  $XY$  siendo definido en la Ecuación 4.2:

$$y = a(x - b)^2 + c \quad (4.2)$$

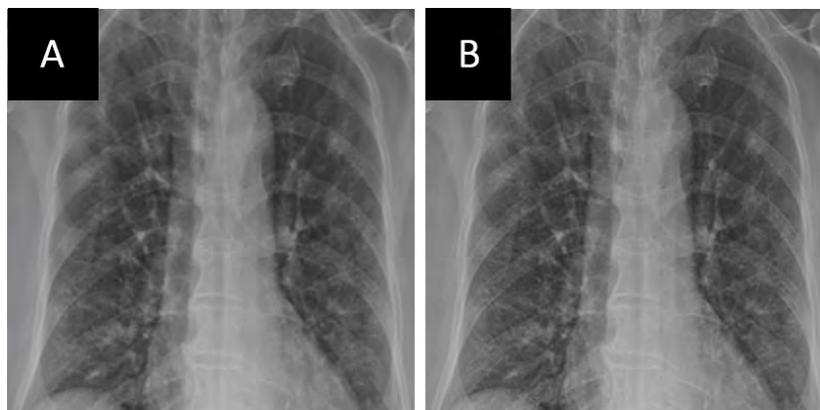
donde, los tres coeficientes  $a$ ,  $b$  y  $c$ , se determinan a partir de las siguientes ecuaciones utilizando los valores mínimo, máximo y promedio de los valores de imagen de entrada y salida:

$$b = \frac{h^2(E-L) - s(H-L) + l^2(H-E)}{2[h(E-L) - e(H-L) + l(H-E)]} \quad (4.3)$$

$$a = \frac{H-L}{(h-l)(h+l-2b)} \quad (4.4)$$

$$c = L - a(l - b)^2 \quad (4.5)$$

donde,  $l$  es el valor mínimo de la imagen de entrada,  $h$  el valor máximo de la imagen de entrada,  $e$  el valor medio de la imagen de entrada,  $L$  el valor mínimo de la imagen de salida,  $H$  el valor máximo de la imagen de salida y  $E$  el valor medio de la imagen de salida. En la Figura 4.5, se observa la aplicación del filtro a una radiografía de tórax de un paciente COVID-19 del conjunto normalizado (Gan, 2020).



**Figura 4. 5.** Radiografía de tórax positivo a COVID-19 A) Original. B) Radiografía aplicado filtro de BCET.

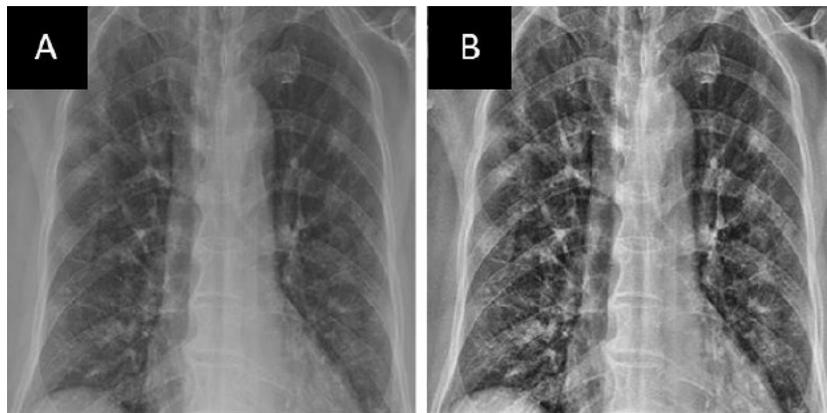
Al aplicar esta técnica puede ser observado en el capítulo 5 de experimentación en las secciones 5.2.3 y 5.2.5; debido a su múltiple implementación durante los experimentos realizados.

### **Ecuación Adaptativa del Histograma Limitada por el Contraste**

Se aplicaron al conjunto de imágenes normalizados el filtro de Ecuación de Histograma Adaptativa y Limitada por el Contraste (CLAHE, siglas en inglés), el cual consiste en una técnica de preprocesamiento variante de la técnica de ecualización de histograma, que se utiliza con frecuencia para mejorar diferentes tipos de imágenes médicas. Esta técnica distribuye eficazmente los valores de intensidad más frecuentes en las imágenes, se secciona la imagen en bloques más pequeños denominados mosaicos y cada uno de estos mosaicos se ecualiza por histograma para confinar la

dispersión de los valores de intensidad en esa región en particular, implementando la ecuación general de ecualización por histograma, expresada en la Ecuación 4.1.

Existe la posibilidad de que el ruido se establezca en un área pequeña amplificándose. Para evitar esto, se aplica la limitación del contraste, donde si alguna casilla del histograma está por encima del límite de contraste especificado, esos píxeles se recortan y se distribuyen uniformemente a otras casillas mediante un umbral para la limitación del contraste, determinando el valor de 2.0. Después de la ecualización, es aplicada la interpolación bilineal para eliminar posibles artefactos en los bordes de los mosaicos; en la Figura 4.6, se puede observar el resultado obtenido al aplicar el filtro a la radiografía aún paciente confirmado con COVID-19 (Singh, 2021).



**Figura 4. 6.** Radiografía de tórax positivo a COVID-19 A) Original. B) Radiografía aplicado filtro CLAHE.

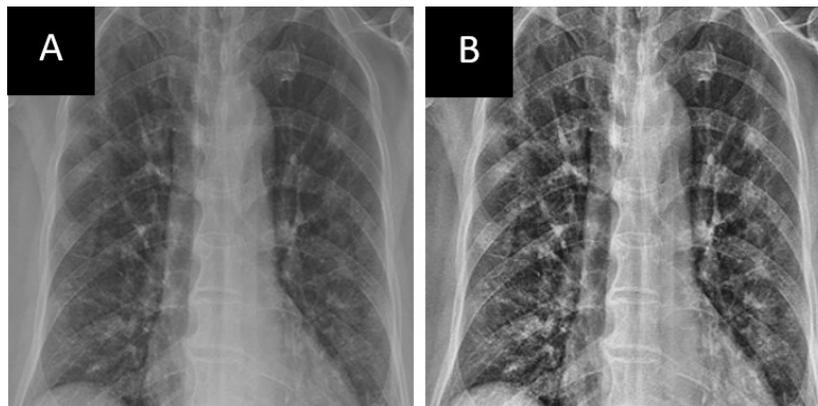
Su desempeño al aplicar esta técnica puede observar en el capítulo 5 de experimentación en las secciones 5.2.3 y 5.2.5, donde se muestra que el modelo con mejor rendimiento en la experimentación fue el modelo propuesto VGG-16 implementando la técnica de CLAHE, obteniendo un 82.61% de exactitud con 100 épocas de entrenamiento; en la sección 5.2.5 se muestra la implementación de la técnica en conjunto con el modelo VGG-16, durante estas pruebas obtuvo una exactitud del 77.23% al implementar un el conjunto en crudo en tres canales (RGB); debido a su eficiente resultado de esta técnica de filtrado se procedió a realizar su sintonización en la sección 5.2.6, se estableció la implementación de este filtro con una casilla de dimensión 8×8 con un umbral de 3.0, se obtuvo un 89.64% de exactitud; consecuentemente en la sección 5.2.7 se realizó la sintonización de hiper parámetros del modelo VGG-16 con esta técnica obteniendo un 90.09% de exactitud. Debido al desarrollo del modelo al implementar esta técnica de filtrado en la serie de experimentaciones realizadas, se sometió a una última prueba con el conjunto de datos aumentado, mostrado en la sección 5.3, obteniendo un 92.34% de exactitud en la clasificación de COVID-19 y NOCOVID-19.

## Corrección Gamma

Los sensores de imagen y los dispositivos de visualización generalmente tienen características de intensidad no lineales, entonces se procede a implementar este filtro para utilizar la linealidad de la intensidad de los píxeles obtenida por el dispositivo de captura de radiografía. Dado que la no linealidad se caracteriza por una ley de potencia y  $\gamma$  es el símbolo utilizado para los exponentes, esta operación se denomina corrección *gamma*. Para compensar esta no linealidad, se debe aplicar una transformación inversa a cada píxel de la imagen,

$$i_{new} = i^\gamma \quad (4.6)$$

donde, el nuevo valor de intensidad del píxel  $i_{new}$  es su valor actual  $i$  elevado a la potencia de  $\gamma$ . Considerando como intensidad máxima 255. Primero divide todos los valores de píxeles por 255 y asigne el valor de intensidad al rango 0 – 1. Este paso asegura que el valor de los píxeles permanezca en el rango de 0 – 255. El valor del resultado se multiplica por 255 y se redondea para obtener el valor procesado. Para  $\gamma < 1$ , los valores de intensidad se escalan y la imagen de salida es más brillante. Para  $\gamma > 1$ , los valores de intensidad se reducen. Además de corregir la no linealidad de los dispositivos, esta transformación también puede utilizarse para manipular el contraste de las imágenes. En la Figura 4.7, se muestra la implementación del filtro en una radiografía de tórax de un paciente confirmado por COVID-19 (Sundararajan, 2017).



**Figura 4. 7.** Radiografía de tórax positivo a COVID-19 A) Original. B) Radiografía aplicado filtro de gamma.

Su desempeño al aplicar esta técnica puede ser observado en el capítulo 5 de experimentación en las secciones 5.2.3 y 5.2.5; debido a su múltiple implementación durante los experimentos realizados.

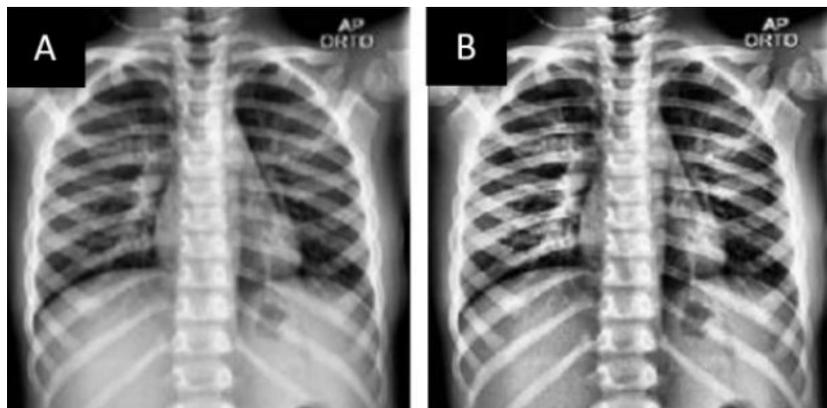
## Método de mejora de imagen NCLAHE

Por último, se aplicó al conjunto de datos el método NCLAHE es una combinación de la función de normalización y el método de Ecuación adaptativa del histograma de límite de contraste (CLAHE, siglas en inglés). Primeramente, se aplica la corrección de intensidad general de la imagen original se normaliza a la imagen escaneada en blanco mediante una función logarítmica. Después, se implementa el método CLAHE para calcular la mejora del contraste local.

La normalización es el proceso de cambiar el rango de valores de intensidad de píxeles de acuerdo con la ley de Beer. El propósito de la expansión del rango dinámico en aplicaciones de imágenes digitales de radiografías, suele implementarse para producir imágenes con valores de visualización adecuados (*PNormalize*), que se describen en la Ecuación 4.7,

$$PNormalize = \log \left( \frac{P_{Blank}}{P_{Raw}} \right) \quad (4.7)$$

donde, *PNormalize* es una imagen de radiografía normalizada, *PBlank* es una imagen de rayos X sin ningún objetivo y *PRaw* es una imagen de radiografía ordinaria. En la Figura 4.8, se puede observar el filtro aplicado (Gan, 2020).

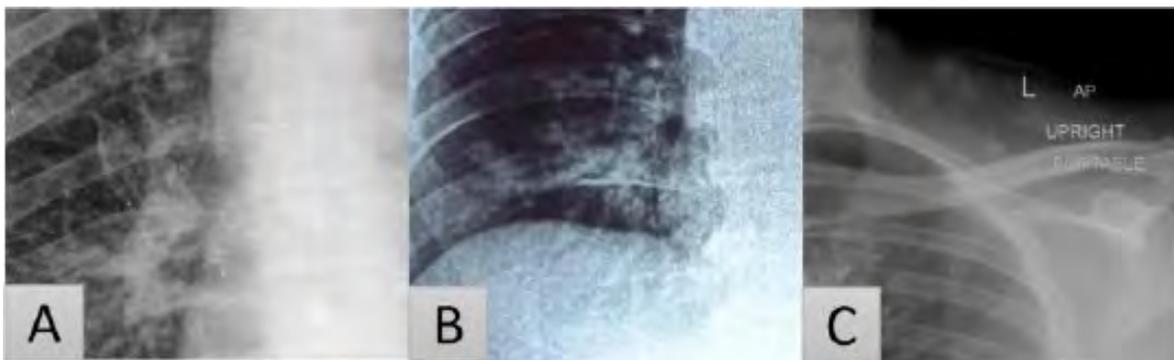


**Figura 4. 8.** Radiografía de tórax de paciente con COVID-19 A) Original. B) Radiografía aplicado filtro NCLAHE.

Su desempeño al aplicar esta técnica puede ser observado en el capítulo 5 de experimentación en las secciones 5.2.3 y 5.2.5; debido a su múltiple implementación durante los experimentos realizados.

### 4.3.3 Aumento del conjunto de datos

Se implementó la técnica de preprocesamiento denominada como normalización, la cual, consiste en realizar un cribado y tratamiento de las imágenes de radiografías, mediante técnicas básicas de edición; descartando de las imágenes las partes de estas donde se presentaban objetos, ya sean dispositivo médicos, objetos personales del paciente, etiquetas de información cercanas al área pulmonar (Figura 4.9 A) o imágenes de reducida calidad por la presencia de ruido impulsivo (Figura 4.9 B) y ruido gaussiano (Figura 4.9 C); implementado en las experimentaciones realizadas en la sección 5.2 que utilizan el conjunto de datos sometidos a la normalización. Para mejorar el desempeño de 90.09% de Exactitud del modelo de red VGG-16 propuesto y eficientizar su predicción, se realizó el procesamiento de las imágenes de radiografía rechazadas en el proceso de normalización del conjunto.

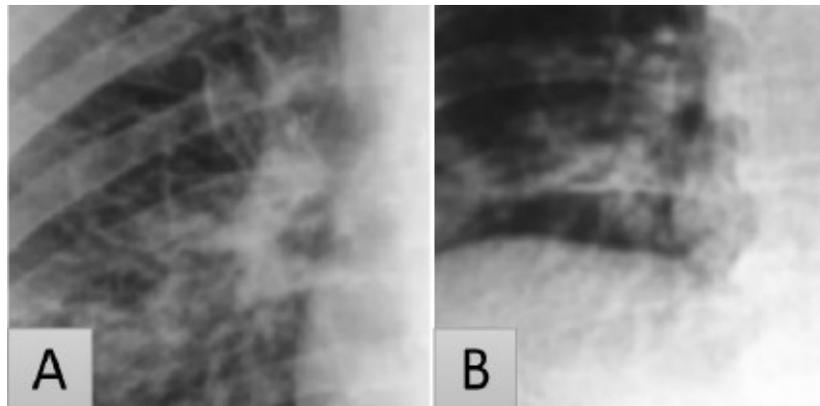


**Figura 4. 9.** Radiografías excluidas por el proceso de normalización. A) Ruido Impulsivo, B) Ruido Gaussiano y C) Etiqueta compleja de editar.

### Procesamiento de las imágenes con ruido Impulsivo y Gaussiano

Para poder utilizar las imágenes con la presencia de ruido Impulsivo y Gaussiano, se requirió experimentar con diferentes tipos de técnicas de filtrado y evaluar visualmente la imagen, para considerar su implementación.

Después, de analizar diferentes técnicas se determinó implementar la técnica de Difusión anisotrópica; también llamada difusión de *Perona-Malik*, la cual es una técnica que tiene como objetivo reducir el ruido de la imagen sin eliminar partes significativas del contenido de esta, generalmente bordes, líneas u otros detalles que son importantes para la interpretación de la imagen. Gracias a la implementación se pudieron considerar para entrenamiento las imágenes descartadas del proceso de normalización. En la Figura 4.10, se puede observar la mejora de la imagen obtenida después del proceso de filtrado.



**Figura 4. 10.** Radiografías después del aplicar el filtro de Difusión anisotrópica. A) Ruido Impulsivo, B) Ruido Gaussiano.

### Descartar objetos presentes en radiografías torácicas

Debido a que se presentaron una gran cantidad de radiografías con presencia de objetos cercanos al área pulmonar, se procedió a implementar el algoritmo denominado *Resolution-robust Large Mask Inpainting with Fourier Convolutions (LaMa*, por sus siglas en inglés) (Suvorov, et al., 2021). *LaMa* se basa en una nueva arquitectura de red de *inpainting* que utiliza convoluciones rápidas de Fourier para eliminar objetos presentes en la imagen, como puede observarse su desempeño en la Figura 4.11, siendo la imagen original la mostrada en la Figura 4.9 C.



**Figura 4. 11.** Radiografía después de aplicar *LaMa* para eliminar la etiqueta realizada por el dispositivo de captura.

Al implementar las técnicas de procesamiento de imágenes para reducir el ruido Impulsivo y Gaussiano, así como el método de descarte de objetos en la radiografía, se obtuvo un nuevo conjunto de datos que presentó un aumento del 11.9%, como se puede observar en la Tabla 4.5.

**Tabla 4. 5.** Conjunto de imágenes aumentado.

Clases de patologías	Previo al aumento	Después del aumento	Porcentaje de aumento
COVID-19	3,336	3,733	11.9%
NOCVID-19	3,336	3,733	11.9%

Mayores detalles sobre el aumento realizado, pueden ser observados en la sección 5.3, donde se muestra una serie de experimentos del desempeño del modelo VGG-16 implementando este nuevo conjunto de datos aumentado, en conjunto con la normalización de los datos y la técnica de filtrado CLAHE sintonizada.

## 4.4 Análisis y selección de técnicas de clasificación

En la revisión de la literatura de trabajos relacionados (sección 3.2), se observó el desarrollo de diferentes trabajos de investigación para la clasificación de COVID-19 y de otras enfermedades respiratorias implementando imágenes de radiografía de tórax, de esta investigación se denota la presencia de dos tipos de técnicas de clasificación: los modelos enfocados en el *machine learning* y los basados en *deep learning*; de las investigaciones que se han realizado, se destacan los modelos de *deep learning* debido a su proceso de abstracción de características en imágenes de radiografía y en su factible clasificación entre patologías, resaltando las Redes Neuronales Convoluciones, específicamente seis modelos que se destacan debido a su presencia en múltiples trabajos previos y por su eficiente desempeño, siendo estos VGG-16, VGG-19, Xception, MobileNetV1, MobileNetV2 y ResNet50.

### 4.4.1 Implementación de una red neuronal convolucional para la clasificación de radiografía de tórax

En la revisión de los trabajos relacionados realizados con mejores desempeños que implementaron redes neuronales convoluciones para la clasificación de imágenes de radiografía de tórax entre las clases de COVID-19 y otras enfermedades respiratorias; destacando de estos trabajos seis modelos de redes neuronales convolucionales debido a su presencia en múltiples trabajos previos y por su eficiente rendimiento en el proceso de clasificación, siendo estos: VGG-16, VGG-19, Xception, MobileNetV1, MobileNetV2 y ResNet50 (descritos a detalle en la sección 2.6.1). Estos modelos procedieron a ser sometidos a prueba en la etapa de experimentación (sección 5.2.2).

Durante la etapa de experimentación, se observó que la implementación del modelo VGG-16 demostró un desempeño eficiente y factible en comparativa con los demás modelos experimentados; debido a esto el modelo VGG-16 fue seleccionado como el modelo base del modelo propuesto de este trabajo de investigación. Se consideró como

base la arquitectura del modelo VGG-16, al cual se le tuvo que realizar modificaciones debido a la problemática presentada este trabajo; de esta forma se procedió a realizar el diseño del modelo propuesto.

#### 4.4.2 Modelo de Red Neuronal Convolutacional Propuesto

El modelo de red neuronal convolutacional propuesto se basa en VGG-16 y presenta la siguiente arquitectura:

La primera y segunda capas convolucionales están compuestas por 64 filtros de núcleo de características y el tamaño de núcleo de  $3 \times 3$ . Se estableció que la imagen de entrada, que es de 3 canales (imagen RGB tiene una profundidad de tres) pasa a la primera y segunda capa convolutacional y sus dimensiones cambian a  $224 \times 224 \times 64$ . Consecuentemente, la salida resultante se pasa a la capa de *max pooling* con un *stride* de 2.

La tercera y cuarta capas convolucionales son de 124 filtros de núcleo de características y el tamaño de núcleo de  $3 \times 3$ . Estas dos capas van seguidas de una capa de agrupación máxima con un *stride* de 2 y la salida resultante se reduce a  $56 \times 56 \times 128$ .

Las capas quinta, sexta y séptima son capas convolucionales con un tamaño de núcleo de  $3 \times 3$  y las tres utilizan 256 características. Estas capas van seguidas de una capa con un *stride* de 2.

De la capa octava a la decimotercera son dos conjuntos de capas convolucionales con un tamaño de núcleo de  $3 \times 3$ . Todos estos conjuntos de capas convolucionales tienen 512 filtros de núcleo. Estas capas van seguidas de una capa de *max pooling* con un *stride* de 1.

Para poder implementar el modelo VGG-16 en este trabajo de investigación se realizó una modificación en la arquitectura del modelo; mediante la técnica de ajuste fino modelo VGG-16, se eliminó la última capa del modelo, se estableció una capa de apilamiento, además, se anexaron 2 capas totalmente conectadas de 128 neuronas y una última capa densa con 2 neuronas utilizando como función de activación la de *softmax*. Estableciendo, las capas catorce y quince como capas totalmente conectadas de 128 neuronas, seguidas de una capa de salida *softmax* (decimosexta capa) para la clasificación binaria de las clases COVID-19 y NOCOVID-19, en la Figura 4.16 se puede observar el modelo propuesto y en la Figura 4.17 se observa la arquitectura del modelo.

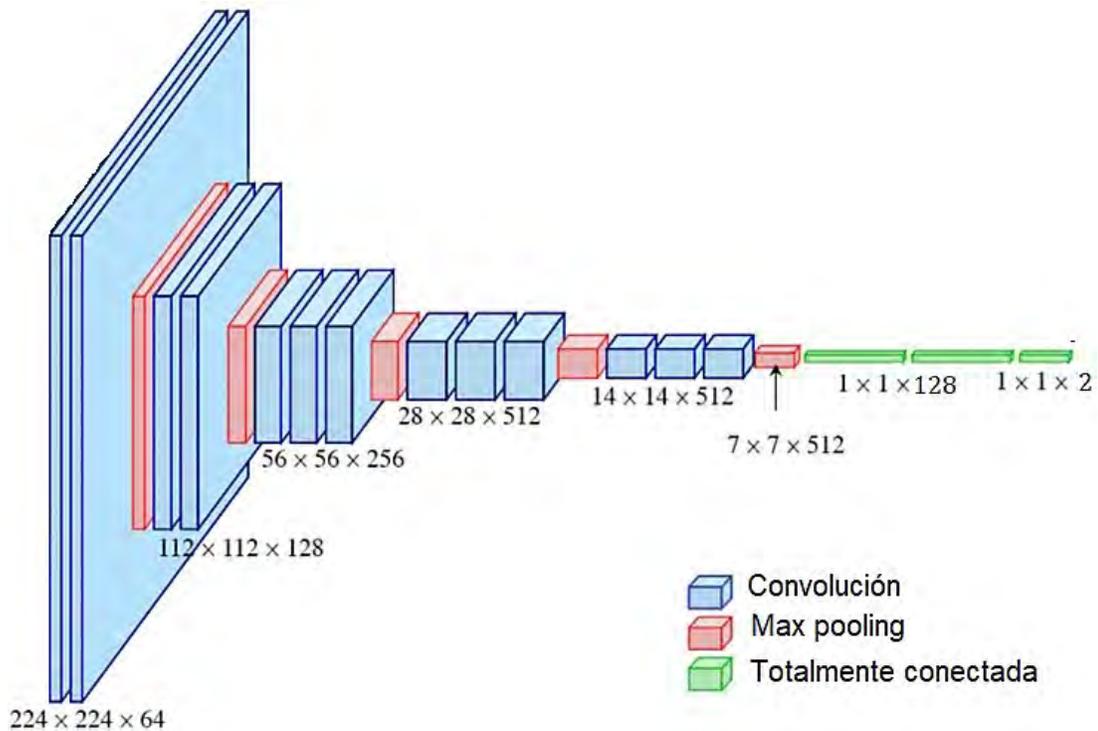


Figura 4. 16. Diseño del modelo propuesto.

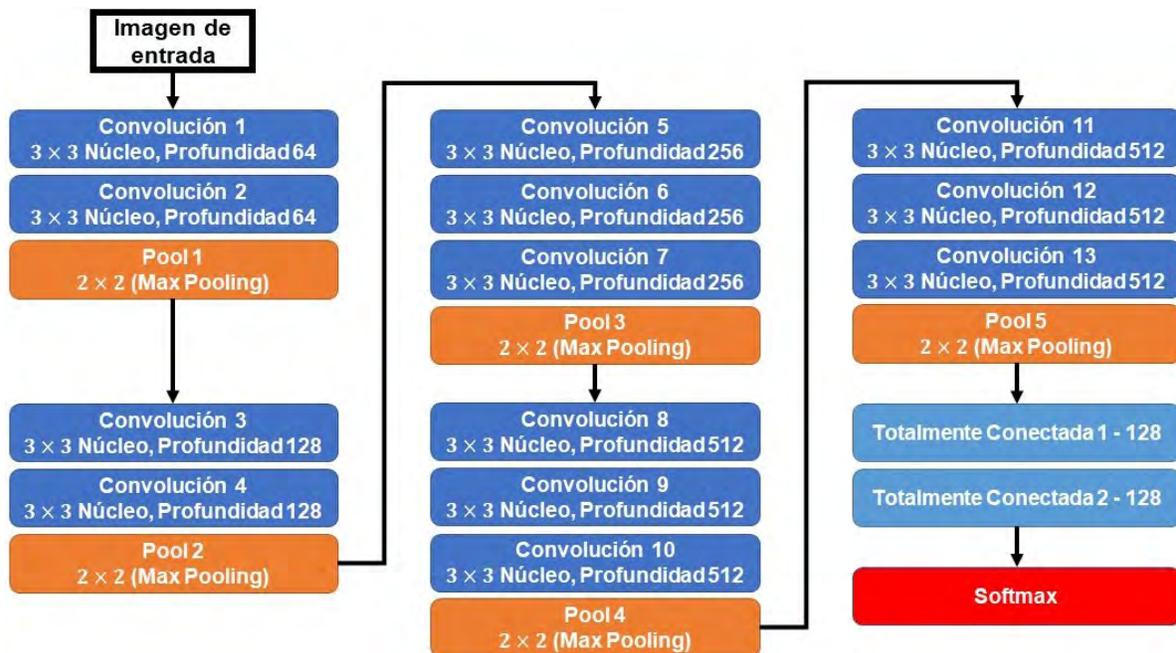
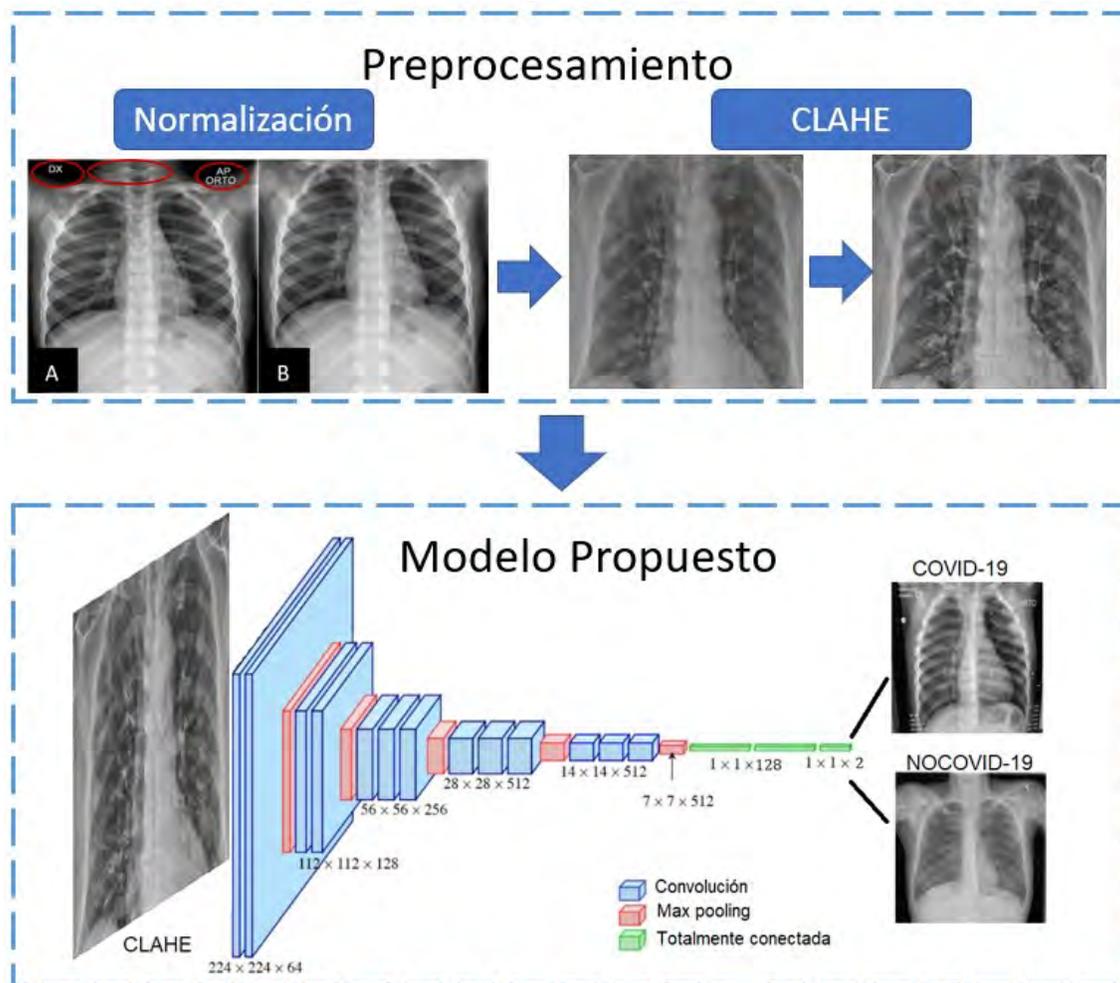


Figura 4.17. Arquitectura del modelo de Red Neuronal Convulsional propuesto.

En la Figura 4.18, se muestra de manera ilustrativa la integración entre el proceso de normalización del conjunto de datos, la implementación de técnicas de filtrado para

la mejora de la calidad de la imagen de radiografía para el apoyo de la red en el proceso de extracción de características durante el entrenamiento y la implementación del modelo propuesto para la clasificación de imágenes de radiografía de tórax en las clases COVID-19 y NOCOVID-19.



**Figura 4.18.** Preprocesamiento del conjunto de datos y modelo propuesto.

## Capítulo 5

### Experimentación y pruebas

En este capítulo, se describen las series de experimentos realizadas en este trabajo de investigación para: la selección del modelo de Red Neuronal Convolutiva a implementar, la evaluación del desempeño de las técnicas de preprocesamiento, la sintonización del modelo propuesto, y la prueba en un entorno real.

#### 5.1 Reporte de Experimentación

Recopilado el conjunto de datos de imágenes de radiografía de tórax de pacientes de COVID-19, otras enfermedades respiratorias y afectaciones pulmonares; se realizó una serie de experimentos dividido en 7 fases, siendo estas las siguientes:

- Experimentación implementando el conjunto de datos en crudo y técnica de *freezing*.
- Experimentación de Redes Neuronales Convolutivas con datos en crudo y normalizados.
- Experimentaciones implementando el conjunto de datos normalizados con técnicas de preprocesamiento de filtrado y RNC VGG-16.
- Experimento con un mayor conjunto de datos en crudo y entrenamiento.
- Experimentos con datos en crudo aplicando técnicas de filtrado.
- Sintonización de la técnica de Filtrado CLAHE del modelo VGG-16.
- Sintonización de hiperparámetros del modelo de Red Neuronal Convolutiva propuesto.

##### 5.1.1 Entorno de desarrollo

Para realizar el proceso de experimentación, el cual consiste en la implementación de modelos de Redes Neuronales Convolutivas; fue requerido utilizar una arquitectura de hardware que contara con una unidad gráfica de procesamiento (GPU) debido a la alta tasa de procesamiento de datos a implementar, permitiendo de esta manera realizar el proceso de entrenamiento de los modelos a experimentar y la evaluación cuantitativa de estos.

Arquitectura de software:

- Sistema operativo Ubuntu 16.04.7 LTS
- Python 3.10
- TensorFlow versión 2.1
- Numpy versión 1.20
- Matplotlib
- Librería Keras

Arquitectura de hardware:

- Tarjeta gráfica: Tesla P100 de 12 GB HBM2 de memoria con 3,584 Núcleos CUDA.
- RAM: 25.45 GB
- Almacenamiento: 166.77 GB

## 5.1.2 Parámetros base establecidos

Hiperparámetros:

- Tasa de aprendizaje: 0.001
- Técnica de optimización: ADAM
- Tamaño de lotes: 32 imágenes
- Dimensiones de las imágenes: 224 × 224
- Transferencia de aprendizaje: Preentrenamiento con el conjunto de imágenes ImageNet

Segmentación del conjunto de imágenes:

Se realizará la división de los conjuntos de imágenes en 3 grupos, en 60% para entrenamiento, 20% para validación y 20% para pruebas.

Aumento de datos:

- Rotación de 10 grados.
- Desplazamiento de anchura
- Desplazamiento de la altura
- Acercamiento de 10

Técnica de depurado:

- *Dropout* al 20%.

### 5.1.3 Base de datos

Se realizó la recopilación de diferentes conjuntos de imágenes de radiografía de tórax de pacientes infectados con la patología de COVID-19, infección viral distinta a COVID-19, neumonía generada por infección bacteriana; además, de imágenes de sujetos que presentaban afectaciones pulmonares referentes a alguna otra enfermedad respiratoria (refiriéndose a este conjunto como NOCOVID-19). Las imágenes de radiografías se encuentran en estado en crudo, este estado consiste en que a las imágenes no se les aplicó técnicas de preprocesamiento, únicamente se realizó la redimensión de estas de  $224 \times 224 \times 3$ , pero debido a que son imágenes de radiografía en los 3 canales de color la imagen repite el mismo valor para cada canal y esta manera implementar una imagen de escala de gris. En la Tabla 5.1, se muestra el conjunto de datos recopilados en estado en crudo.

**Tabla 5. 1.** Conjunto de datos recopilado en crudo.

Conjunto de imágenes	Clases de patologías			
	COVID-19	Neumonía Bacteriana	Neumonía Viral	NOCVID-19
Repositorio desarrollado	6,050	2,767	2,630	10,969

### Implementación de Técnicas de Filtrado en Radiografías de Tórax

Se utilizaron las cinco técnicas de preprocesamiento de filtrado analizadas en la sección 4.3.2, siendo aplicados de manera independiente a los distintos conjuntos desarrollados teniendo como base al conjunto conformado como repositorio en la recopilación de diferentes conjuntos de datos de acceso público; disponiendo para experimentación los conjuntos de datos en crudo, normalizados y el conjunto aumentado. Las técnicas de filtrado HE, BCET, CLAHE, NCLAHE y Corrección Gamma, implementada; fueron previamente sintonizadas, los filtros que implemente valores configurables (pero debido a que la técnica de CLAHE obtuvo un desempeño destacable se realizó nuevamente su sintonización de configuración). La Figura 5.1, ilustra los resultados de aplicar las Técnicas de Filtrado a una imagen de radiografía de tórax de un paciente confirmado con COVID-19.



**Figura 5. 1.** Radiografía de tórax positivo a COVID-19, A) Crudo. B) HE, C) BCET, D) CLAHE, E) NCLAHE y F) Corrección Gamma.

## 5.1.4 Métricas

Las métricas implementadas en las series de experimentos para evaluar cuantitativamente el desempeño del modelo a experimentar fueron seleccionados con base en la literatura, con el objetivo de realizar un análisis comparativo de los modelos experimentados; las métricas implementadas son: Exactitud, Precisión, Valor-F1 y Sensibilidad, tal como son descritas en el capítulo 2 en la sección 2.8 de este documento.

## 5.2 Experimentos desarrollados

### 5.2.1 Experimentación implementando el conjunto de datos en crudo y técnica de *Freezing*

Se realizó la evaluación cuantitativa del desempeño obtenido con los modelos de Redes Neuronales Convolucionales VGG-16, VGG-19, Xception, MobileNetV1, MobileNetV2 y ResNet50 en la clasificación multiclase de COVID-19, Neumonía Bacteriana, Neumonía Viral y NOCOVID-19, implementando la técnica de transferencia de aprendizaje de *freezing* y no utilizando dicha técnica.

#### Base de datos para implementación

Se usó el conjunto recopilado, siendo estas imágenes en crudo descritas en la Tabla 5.1; se utilizaron las imágenes de radiografía correspondiente a las patologías COVID-19, Neumonía Bacteriana, Neumonía Viral y NOCOVID-19, pudiendo observarse dicho conjunto en la Tabla 5.2.

**Tabla 5. 2.** Distribución del conjunto de entrenamiento con imágenes en crudo.

Clases de las patologías	Entrenamiento (60%)	Validación (20%)	Prueba (20%)
COVID-19	1,578	526	526
Neumonía Bacteriana	1,578	526	526
Neumonía Viral	1,578	526	526
NOCVID-19	1,578	526	526

#### Desarrollo

Cada modelo fue preentrenado con el conjunto de imágenes ImageNet; además, se aplicó la técnica de ajuste fino que consiste en eliminar las últimas dos capas del modelo preentrenado, se integró una capa de apilamiento, después se anexaron 4 capas densas de 128 neuronas y una última capa densa con 2 neuronas utilizando como función de activación *softmax*; finalmente en estas capas se implementó el método de *dropout* al 20%.

Se comparó el desempeño logrado al aplicar la técnica de *freezing*, la cual consistió en únicamente entrenar a las últimas dos capas totalmente conectadas con el conjunto de imágenes de COVID19 y NOCOVID-19, conservando los pesos sinápticos de los modelos preentrenados en capas previas, contra el desempeño alcanzado al ajustar los valores de los pesos sinápticos de todos modelos de red experimentados, mediante el entrenamiento todas sus capas sin conservar los pesos sináptico obtenidos del preentrenamiento.

Para el entrenamiento se estableció la cantidad de 20 épocas de entrenamiento para esta evaluación. En la Tabla 5.3, se puede observar el desempeño obtenido con la métrica de exactitud en cada modelo de aprendizaje experimentado, implementando la técnica de *freezing* y sin *freezing*.

**Tabla 5. 3.** Desempeño de los modelos implementado *freezing*.

Modelo	Técnica	Exactitud
VGG-19	Freezing	0.2200
	Sin Freezing	0.2700
VGG-16	Freezing	0.2800
	Sin Freezing	0.3210
MobileNet_V1	Freezing	0.2300
	Sin Freezing	0.2500
MobileNet_V2	Freezing	0.2100
	Sin Freezing	0.2300
Xception	Freezing	0.2000
	Sin Freezing	0.2200
ResNet50	Freezing	0.2100
	Sin Freezing	0.2600

Como puede observarse en la tabla anterior, se obtuvieron mejores resultados al no implementar la técnica de *freezing* y consecuentemente, se optó por dejar de implementarla en las siguientes pruebas. Además, se debe destacar de esta prueba que el modelo VGG-16 presenta un mejor desempeño que los demás modelos.

## 5.2.2 Experimentación de Redes Neuronales Convolucionales con datos en crudo y normalizados

Se realizó la evaluación cuantitativa del desempeño de los modelos VGG-16, VGG-19, MobileNetV1, MobileNetV2 y ResNet50; en la clasificación multiclase (COVID-19, Neumonía Viral, Neumonía Bacteriana y NOCOVID-19) y binaria (COVID-19 y NOCOVID-19), tanto con los conjuntos de datos en crudo (sin aplicar ninguna técnica de preprocesamiento de filtrado para realzar características de la imagen) y como con los datos normalizados (mediante la técnica de normalización).

## Experimento con conjunto de datos en crudo con multiclase

En la prueba se evaluó el desempeño de los modelos VGG-16, VGG-19, Xception, MobileNetV1, MobileNetV2 y ResNet50, implementando el conjunto de imágenes en crudo recopilado en la clasificación multiclase: COVID-19, Neumonía Viral, Neumonía Bacteriana y NOCOVID-19.

### Base de datos implementada

Para la experimentación se implementó el conjunto de imágenes en crudo multiclase descrito en la Tabla 5.1; debido a que este conjunto se encuentra desbalanceado entre clases para un entrenamiento justo se procedió a realizar el balance del conjunto considerando a la clase con menor cantidad de radiografías, siendo esta la clase de Neumonía Viral. Como resultado, se generó un nuevo conjunto de datos de experimentación respetando la distribución de las imágenes de 60% para entrenamiento, 20% para validación y 20% para prueba; en la Tabla 5.4 se puede observar el resumen cuantitativo de dicho conjunto de imágenes.

**Tabla 5. 4.** Conjunto de imágenes en crudo distribuido para entrenamiento.

Clases de las patologías	Entrenamiento (60%)	Validación (20%)	Prueba (20%)
COVID-19	1,578	526	526
Neumonía Bacteriana	1,578	526	526
Neumonía Viral	1,578	526	526
NOCOVID-19	1,578	526	526

### Desarrollo

Para realizar esta prueba se implementó la técnica de ajuste fino, que consiste en eliminar la última capa de cada modelo, establecer una capa de apilamiento, después agregar 2 capas densas de 128 neuronas y una última capa con 4 neuronas que se implementaron con la función de activación *softmax*. Además, se implementaron los parámetros base establecidos, se ajustaron los valores de los pesos sinápticos de las últimas capas integradas y se estableció la cantidad de 50 épocas de entrenamiento; además, se utilizó la técnica de *dropout* al 20%. En la Tabla 5.5, se puede observar la evaluación cuantitativa del desempeño por clase y general con los diferentes modelos de aprendizaje profundo.

**Tabla 5. 5.** Desempeño de los modelos implementados en conjuntos de imágenes en crudo.

Modelo	Clases	Exactitud	Precisión	Sensibilidad	Valor-F1
VGG-19	Bacteriana	0.2500	0.2500	1.0000	0.4000
	COVID-19		0.0000	0.0000	0.0000
	NOCOVID-19		0.0000	0.0000	0.0000
	Viral		0.0000	0.0000	0.0000
	General		0.0625	0.2500	0.1000
VGG-16	Bacteriana	0.4227	0.6169	0.4618	0.5282
	COVID-19		1.0000	0.1103	0.1986
	NOCOVID-19		0.3398	0.9924	0.5063
	Viral		0.5546	0.1255	0.2047
	General		0.6278	0.4225	0.3595
MobileNet_V1	Bacteriana	0.2500	0.0000	0.0000	0.0000
	COVID-19		0.0000	0.0000	0.0000
	NOCOVID-19		0.2500	1.0000	0.4000
	Viral		0.0000	0.0000	0.0000
	General		0.0625	0.2500	0.1000
MobileNet_V2	Bacteriana	0.2400	0.2447	0.7643	0.3707
	COVID-19		0.2000	0.0209	0.0379
	NOCOVID-19		0.2238	0.0608	0.0957
	Viral		0.2281	0.1141	0.1521
	General		0.2241	0.2400	0.1641
Xception	Bacteriana	0.2500	0.2500	1.0000	0.4000
	COVID-19		0.0000	0.0000	0.0000
	NOCOVID-19		0.0000	0.0000	0.0000
	Viral		0.0000	0.0000	0.0000
	General		0.0625	0.2500	0.1000
ResNet50	Bacteriana	0.3883	0.3033	0.0703	0.1142
	COVID-19		0.3624	0.4734	0.4106
	NOCOVID-19		0.4305	0.4240	0.4272
	Viral		0.3964	0.5856	0.4728
	General		0.3732	0.3883	0.3562

El desempeño de cada uno de los modelos presentados para la clasificación multiclase fue muy deficiente, por lo que se optó por realizar una clasificación binaria considerando las clases COVID-19 y NOCOVID-19 con datos en crudo. Sin embargo, en esta serie de experimentación hay que resaltar que VGG-16 presentó el mayor desempeño en las diferentes métricas de evaluación durante el proceso de clasificación multiclase, resaltando el 42.27% de exactitud obtenido.

## Experimentación con el conjunto de datos en crudo clasificando COVID-19 y NOCOVID-19

Debido a los resultados obtenidos en la experimentación previa, en esta prueba se evaluó el desempeño de los modelos VGG-16, VGG-19, Xception, MobileNetV1, MobileNetV2 y ResNet50; implementando el conjunto de imágenes en crudo en clasificación binaria, siendo las clases consideradas COVID-19 y NOCOVID-19.

### Base de datos implementada

Para esta experimentación se implementó una clasificación binaria entre las clases COVID-19 y NOCOVID-19; considerando el conjunto de imágenes en crudo (Tabla 5.2), considerando una clasificación binaria entre las clases COVID-19 y NOCOVID-19; consistiendo en no implementar técnicas de preprocesamiento de filtrado y se aplicaron los parámetros base establecidos previo a su implementación. Debido a que se realizó una clasificación binaria, se procedió a realizar el balance de estas dos clases, reduciendo la cantidad de imágenes de la clase NOCOVID-19; ajustando esta clase a la de COVID-19, en la Tabla 5.6 se puede observar el subconjunto de imágenes utilizado para la experimentación.

**Tabla 5. 6.** Conjunto de imágenes de radiografías de tórax en crudo.

Clases de las patologías	Entrenamiento (60%)	Validación (20%)	Prueba (20%)
COVID-19	3,638	1,206	1,206
NOCVID-19	3,638	1,206	1,206

### Desarrollo

Para esta experimentación se realizó el entrenamiento de las Redes Neuronales Convolucionales VGG-16, VGG-19, Xception, MobileNetV1, MobileNetV2 y ResNet50 implementado el método de transferencia para cada una mediante el conjunto de imágenes *ImageNet*; consecuente se aplicó la técnica de ajuste fino que consiste en eliminar la última capa de cada modelo, establecer una capa de apilamiento, después anexar 2 capas densas de 128 neuronas y por último, anexar una capa con 2 neuronas utilizando como función de activación *softmax*. Además, se estableció la cantidad de 50 épocas de entrenamiento. En la Tabla 5.7, se puede observar el desempeño obtenido con los diferentes modelos.

**Tabla 5. 7.** Desempeño de los modelos de aprendizaje profundo implementados en el experimento.

Modelo	Clases	Exactitud	Precisión	Sensibilidad	Valor-F1
VGG-19	COVID-19	0.5000	0.0000	0.0000	0.0000
	NOCOVID-19		0.5000	1.0000	0.6667
	General		0.2500	0.5000	0.3333
VGG-16	COVID-19	0.6770	0.9533	0.3723	0.5355
	NOCOVID-19		0.6100	0.9818	0.7525
	General		0.7816	0.6770	0.6440
MobileNet_V1	COVID-19	0.5000	0.0000	0.0000	0.0000
	NOCOVID-19		0.5000	1.0000	0.6667
	General		0.2500	0.5000	0.3333
MobileNet_V2	COVID-19	0.5000	0.5000	1.0000	0.6667
	NOCOVID-19		0.0000	0.0000	0.0000
	General		0.2500	0.5000	0.3333
Xception	COVID-19	0.4988	0.4994	0.9975	0.6656
	NOCOVID-19		0.0000	0.0000	0.0000
	General		0.2497	0.4988	0.3328
ResNet50	COVID-19	0.4598	0.4723	0.6857	0.5594
	NOCOVID-19		0.4266	0.2338	0.3021
	General		0.4495	0.4598	0.4307

El desempeño de cada uno de los modelos presentados en este experimento, demuestra que los modelos presentan un mejor trabajo si se realiza una clasificación binaria en comparativa con la clasificación multiclase, resaltando nuevamente VGG-16 al obtener el mayor valor en exactitud, siendo este del 67.70%.

### **Experimentación con el conjunto de datos normalizados clasificando COVID-19 frente a NOCOVID-19**

En esta prueba se evaluó el desempeño de los modelos de redes neuronales convolucionales VGG-16, VGG-19, Xception, MobileNetV1, MobileNetV2 y ResNet50 en la tarea de clasificación binaria con el conjunto de imágenes normalizado.

#### **Base de datos implementadas**

En esta prueba se implementó el conjunto de imágenes normalizadas, en el que se excluyeron imágenes que presentaron objetos en el área pulmonar. Considerando únicamente las clases COVID-19 y NOCOVID-19, como se detalla en la Tabla 4.4; debido a que solo se consideraron las dos clases previamente mencionadas, se procedió a realizar el balance de estas dos clases, reduciendo la cantidad de imágenes de la clase NOCOVID-19. Además, el conjunto de imágenes normalizadas fue dividido considerando el 60% para entrenamiento, el 20% para validación y el 20% para prueba, como se expresa en la Tabla 5.8.

**Tabla 5. 8.** Conjunto de imágenes de radiografías de tórax normalizado.

Clases de las patologías	Entrenamiento (60%)	Validación (20%)	Prueba (20%)
COVID-19	2,002	667	667
NOCOVID-19	2,002	667	667

## Desarrollo

Las Redes Neuronales Convolucionales VGG-16, VGG-19, Xception, MobileNetV1, MobileNetV2 y ResNet50; se implementaron usando la configuración de los parámetros base establecidos para experimentación y se ajustaron para realizar el proceso de clasificación en dos clases, mediante la técnica de ajuste fino, la cual consiste en eliminar la última capa de cada modelo, establecer una capa de apilamiento después anexar 2 capas densas de 128 neuronas y una última capa densa con 2 neuronas utilizando como función de activación *softmax*. Se estableció la cantidad de 50 épocas de entrenamiento, en la Tabla 5.9 se puede observar el desempeño obtenido con los diferentes modelos de aprendizaje profundo por clase y de manera general en la predicción al evaluar el modelo.

**Tabla 5. 9.** Desempeño de los modelos de aprendizaje profundo implementados en el experimento.

Modelo	Clases	Exactitud	Precisión	Sensibilidad	Valor-F1
VGG-19	COVID-19	0.5000	0.0000	0.0000	0.0000
	NOCOVID-19		0.5000	1.0000	0.6667
	General		0.2500	0.5000	0.3333
VGG-16	COVID-19	0.6807	0.6102	1.0000	0.7580
	NOCOVID-19		1.0000	0.3613	0.5308
	General		0.8051	0.6806	0.6444
MobileNet_V1	COVID-19	0.5000	0.5000	1.0000	0.6667
	NOCOVID-19		0.0000	0.0000	0.0000
	General		0.2500	0.5000	0.3333
MobileNet_V2	COVID-19	0.5000	0.5000	1.0000	1.0000
	NOCOVID-19		0.0000	0.0000	0.0000
	General		0.2500	0.5000	0.5000
Xception	COVID-19	0.5000	0.5000	1.0000	1.0000
	NOCOVID-19		0.0000	0.0000	0.0000
	General		0.5000	0.5000	0.5000
ResNet50	COVID-19	0.5000	0.5000	0.0120	0.0234
	NOCOVID-19		0.5000	0.9880	0.6640
	General		0.5000	0.5000	0.3437

Los resultados de cada uno de los modelos considerados en este experimento, muestran una inclinación hacia una clase en la predicción obtenida, por lo que no factibles para el proceso de clasificación binaria en un entorno real; sin embargo, nuevamente destaca VGG-16 cuyo desempeño fue mayor al implementar datos normalizados en comparativa con el implementar datos en crudo. Debido a este

resultado, se optó por continuar implementando este conjunto de datos normalizados en las siguientes pruebas.

### **5.2.3 Experimentaciones implementando el conjunto de datos normalizados con técnicas de preprocesamiento de filtrado y RNC VGG-16**

Debido a que el conjunto de datos normalizados demostró un mejor desempeño en comparativa con el implementar datos en crudo en el proceso de clasificación; en este apartado se muestra los resultados obtenidos al experimentar con el conjunto de datos normalizados aplicado técnicas de filtrado para imágenes médicas de radiografía de tórax.

#### **Experimentación con el conjunto de datos normalizados aplicando el filtro CLAHE clasificando COVID-19 frente a NOCOVID-19**

##### **Base de datos implementada**

En esta prueba se realizó la experimentación usando el conjunto de imágenes normalizadas descrito en la Tabla 5.8, considerando las clases COVID-19 y NOCOVID-19, con la diferencia de que le fue aplicada la técnica de filtrado de Ecualización de Histograma Adaptativa y Limitada por el Contraste (CLAHE, por sus siglas en inglés).

##### **Desarrollo**

Para esta experimentación se realizó el entrenamiento a la Red Neuronal Convolutiva VGG-16; se utilizó el método de transferencia de conocimiento siendo VGG-16 preentrenada con el conjunto de imágenes ImageNet; consecuente se hizo uso de la técnica de ajuste fino que consistió en eliminar la última capa del modelo, establecer una capa de apilamiento, anexar 2 capas densas de 128 neuronas y una última capa densa con 2 neuronas utilizando la función de activación *softmax* para la clasificación; además en estas capas se implementó el método de *dropout* del 20%.

También se ajustaron los valores de los pesos sinápticos de toda la red mediante su entrenamiento y se establecieron pruebas con 50, 100 y 150 épocas de entrenamiento. En la Tabla 5.10, se puede observar el desempeño en el proceso de evaluación del modelo VGG-16 implementando diferentes épocas de entrenamiento. Dicho modelo obtuvo con 50 épocas de entrenamiento 74.21% de exactitud, con 100 épocas de entrenamiento 82.61% de exactitud y 150 épocas de entrenamiento 68.14% de exactitud.

**Tabla 5. 10.** Desempeño de los modelos de aprendizaje profundo implementados en el experimento.

Modelo	Épocas	Clases	Exactitud	Precisión	Sensibilidad	Valor-F1
VGG-16	50	COVID-19	0.7421	0.9195	0.5307	0.6730
		NOCOV-19		0.6702	0.9535	0.7871
		General		0.7948	0.7421	0.7301
VGG-16	100	COVID-19	0.8261	0.7757	0.9175	0.8407
		NOCOV-19		0.8991	0.7346	0.8086
		General		0.8374	0.8261	0.8246
VGG-16	150	COVID-19	0.6814	0.7145	0.6042	0.6548
		NOCOV-19		0.6571	0.7586	0.7042
		General		0.6858	0.6814	0.6795

## Experimentación con el conjunto de datos normalizados aplicando el filtro Técnica de Mejora de Contraste Equilibrado clasificando COVID-19 frente a NOCOVID-19

### Base de datos implementada

En esta sección se llevó a cabo la experimentación cuando al conjunto de imágenes normalizadas (se puede observar en la Tabla 5.8), considerando las clases COVID-19 y NOCOVID-19, se le aplicó la técnica de filtrado Técnica de Mejora de Contraste Equilibrado (BCET, por sus siglas en inglés).

### Desarrollo

Para esta experimentación se realizó el entrenamiento de la Red Neuronal Convolutiva VGG-16; se utilizaron los métodos de transferencia de conocimiento y ajuste fino como se mencionó anteriormente, definiendo nuevamente pruebas con 50, 100 y 150 épocas de entrenamiento.

En la Tabla 5.11, se puede observar que VGG-16 obtuvo 67.17% de exactitud con 50 épocas de entrenamiento, 77.59% de exactitud con 100 épocas de entrenamiento y 61.28% de exactitud con 150 épocas de entrenamiento.

**Tabla 5. 11.** Desempeño de los modelos de aprendizaje profundo implementados en el experimento.

Modelo	Épocas	Clases	Exactitud	Precisión	Sensibilidad	Valor-F1
VGG-16	50	COVID-19	0.6717	0.9421	0.3658	0.5270
		NOCOV-19		0.6065	0.9775	0.7486
		General		0.7743	0.6717	0.6378
VGG-16	100	COVID-19	0.7759	0.7110	0.9295	0.8057
		NOCOV-19		0.8983	0.6222	0.7352
		General		0.8046	0.7759	0.7704
VGG-16	150	COVID-19	0.6128	0.9892	0.2280	0.3706
		NOCOV-19		0.5637	0.9975	0.7204
		General		0.7765	0.6128	0.6128

## Experimentación con el conjunto de datos normalizados aplicando el filtro de Corrección Gamma clasificando COVID-19 y NOCOVID-19

### Base de datos implementada

En esta sección se llevó a cabo la experimentación implementando el conjunto de imágenes normalizadas, que se puede observar en la Tabla 5.8, considerando las clases COVID-19 y NOCOVID-19, con la diferencia que se le aplicó la técnica de filtrado Corrección de Gamma.

### Desarrollo

Para esta experimentación se realizó el entrenamiento de VGG-16 utilizando los métodos de transferencia de conocimiento y ajuste fino como se ha descrito previamente. También se establecieron pruebas con 50, 100 y 150 épocas de entrenamiento.

En la Tabla 5.12, se puede observar el desempeño alcanzado en las pruebas, mostrando que con 50 épocas de entrenamiento se obtuvo el 77.29% de exactitud, con 100 épocas de entrenamiento el 64.69% de exactitud y con 150 épocas de entrenamiento el 75.94% de exactitud.

**Tabla 5. 12.** Desempeño de los modelos de aprendizaje profundo implementados en el experimento.

Modelo	Épocas	Clases	Exactitud	Precisión	Sensibilidad	Valor-F1
VGG-16	50	COVID-19	0.7729	0.7333	0.8576	0.7906
		NOCVID-19		0.8285	0.6882	0.7518
		General		0.7809	0.7729	0.7712
VGG-16	100	COVID-19	0.6469	0.5864	0.9970	0.7385
		NOCVID-19		0.9900	0.2969	0.4567
		General		0.7882	0.6469	0.5976
VGG-16	150	COVID-19	0.7594	0.7074	0.8846	0.7861
		NOCVID-19		0.8460	0.6342	0.7249
		General		0.7767	0.7594	0.7555

## Experimentación con el conjunto de datos normalizados aplicando el filtro de Ecuilización del Histograma clasificando COVID-19 frente a NOCOVID-19

### Base de datos implementada

En esta sección se llevó a cabo la experimentación implementando el conjunto de imágenes normalizadas, que se puede observar en la Tabla 5.8, considerando las clases

COVID-19 y NOCOVID-19, con la diferencia que se le aplicó la técnica de filtrado Ecuación del Histograma (HE, por sus siglas en inglés).

### Desarrollo

Para esta prueba se realizó el entrenamiento de VGG-16 repitiendo las condiciones de transferencia de conocimiento y ajuste fino, así como la definición de pruebas con 50, 100 y 150 épocas de entrenamiento.

En la Tabla 5.13, se pueden observar los resultados de las pruebas, notando que con 50 épocas de entrenamiento se obtuvo el 72.64% de exactitud, con 100 épocas de entrenamiento el 23.84% de exactitud y con 150 épocas de entrenamiento el 69.34% de exactitud.

**Tabla 5. 13.** Desempeño de los modelos de aprendizaje profundo implementados en el experimento.

Modelo	Épocas	Clases	Exactitud	Precisión	Sensibilidad	Valor-F1
VGG-16	50	COVID-19	0.7264	0.6486	0.9880	0.7831
		NOCVID-19		0.9748	0.4648	0.6294
		General		0.8117	0.7264	0.7063
VGG-16	100	COVID-19	0.2384	0.5673	0.9985	0.7235
		NOCVID-19		0.9938	0.2384	0.3845
		General		0.7805	0.6184	0.5540
VGG-16	150	COVID-19	0.6934	0.6203	0.9970	0.7648
		NOCVID-19		0.9924	0.3898	0.5597
		General		0.8064	0.6934	0.6623

## Experimentación con el conjunto de datos normalizados aplicando el filtro de NCLAHE clasificando COVID-19 frente a NOCOVID-19

### Base de datos implementada

En esta sección se llevó a cabo la experimentación implementando el conjunto de imágenes normalizadas, que se puede observar en la Tabla 5.8, considerando las clases COVID-19 y NOCOVID-19, con la diferencia que se le aplicó la técnica de filtrado NCLAHE.

### Desarrollo

Como con las anteriores pruebas reportadas en este apartado, se entrenó VGG-16; utilizando transferencia de conocimiento y aplicando la técnica de ajuste fino, además de que se establecieron pruebas con 50, 100 y 150 épocas de entrenamiento.

En la Tabla 5.14, se puede observar el desempeño en el proceso de evaluación de VGG-16 implementando diferentes épocas de entrenamiento. Dicho modelo obtuvo

56.30% de exactitud con 50 épocas de entrenamiento, el 77.96% de exactitud con 100 épocas de entrenamiento y el 68.29% de exactitud 150 épocas de entrenamiento.

**Tabla 5. 14.** Desempeño de los modelos de aprendizaje profundo implementados en el experimento.

Modelo	Épocas	Clases	Exactitud	Precisión	Sensibilidad	Valor-F1
VGG-16	50	COVID-19	0.5630	0.9884	0.1274	0.2258
		NOCOVID-19		0.5337	0.9985	0.6956
		General		0.7610	0.5630	0.4607
VGG-16	100	COVID-19	0.7796	0.7151	0.9295	0.8083
		NOCOVID-19		0.8994	0.6297	0.7407
		General		0.8072	0.7796	0.7745
VGG-16	150	COVID-19	0.6829	0.6132	0.9910	0.7576
		NOCOVID-19		0.9766	0.3748	0.5417
		General		0.7949	0.6829	0.6497

## 5.2.4 Experimento con un mayor conjunto de datos en crudo y entrenamiento

Se realizó la experimentación con el conjunto de datos en crudo con las clases COVID-19 y NOCOVID-19 con mayor cantidad de épocas de entrenamiento para determinar si el modelo demostraba un desempeño efectivo sin implementar técnicas de preprocesamiento. Además, en esta experimentación se implementó este conjunto de datos dividido en 2 tipos de dimensiones: 3 canales (siendo estos RGB) y un canal (escala de grises).

### Base de datos implementada

Se estableció el conjunto de imágenes en crudo dividido en 2 clases correspondiente a las patologías COVID-19 y patologías que presentaron anomalías similares a COVID-19, denominando esta clase como NOCOVID-19, pero con la diferencia que ahora se consideró implementar una distribución del conjunto de imágenes del 80% para entrenamiento, 10% para validación y 10% para prueba, mostrado en la Tabla 5.15 la conformación de este conjunto.

**Tabla 5. 15.** Conjunto de imágenes de radiografías de tórax en crudo.

Clases de las patologías	Entrenamiento (80%)	Validación (10%)	Prueba (10%)
COVID-19	4,838	606	606
NOCOVID-19	4,838	606	606

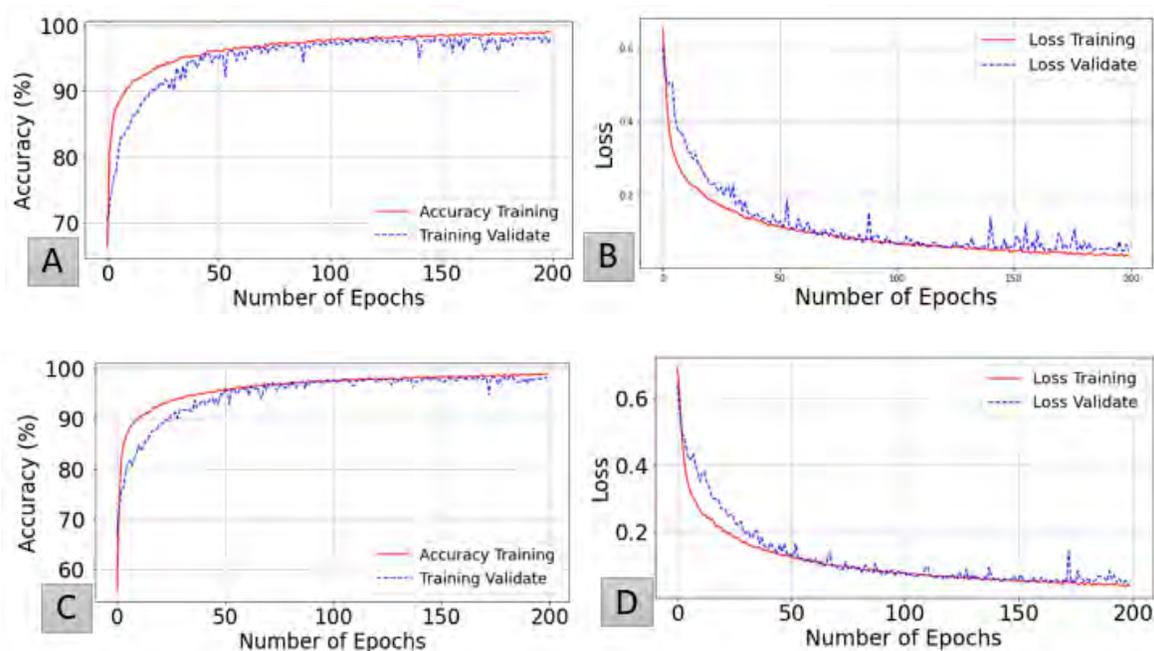
## Configuración de parámetros del entrenamiento

Los parámetros configurados para esta experimentación fueron los siguientes:

- ❖ Aumento de datos del conjunto de entrenamiento:
  - Acercamiento de 10% a la imagen.
  - Rotación de un ángulo del 10%.
  - 10% de desplazamiento a lo alto y largo.
- ❖ Dimensionalidad de las imágenes: 224×224.
- ❖ 200 épocas de entrenamiento.
- ❖ Tamaño del lote de 128 imágenes.
- ❖ Modificación de las dos últimas capas totalmente conectadas: conformando con 128 neuronas cada una.
- ❖ Técnica de abandono del 20%.
- ❖ Optimizador Adadelta con un factor de aprendizaje 0.001 (siendo este una versión modificada que permite poder implementar el cambio de este hiperparámetro).
- ❖ Función de pérdida de entropía cruzada binaria.
- ❖ Función de clasificación softmax.
- ❖ Transferencia de aprendizaje implementando el conjunto ImageNet.

## Entrenamiento de modelos con el conjunto de datos en crudo

Para este entrenamiento se usó el conjunto de imágenes en crudo en escala de grises y RGB; considerando la configuración previamente mencionada. En la Figura 5.2 se observa el desempeño del modelo tomando como referencia la métrica de evaluación *Accuracy* (exactitud) con ambos conjuntos; en la Figura 5.2 (A) se muestra el desempeño en cada época de entrenamiento con el conjunto en escala de grises (EG) y en la Figura 5.2(B) se observa la pérdida que demostró el modelo durante el entrenamiento con esta dimensión el conjunto. En la Figura 5.2(C), se observa el desempeño en cada época de entrenamiento con el conjunto en RGB y en la Figura 5.2(D) se observa la pérdida que demostró el modelo con esta otra dimensión.



**Figura 5. 2.** Desempeño del modelo con datos en crudo con dos tipos de dimensiones. A) Evaluación de la exactitud del modelo con conjunto EG. B) Pérdida obtenido con conjunto EG.C) Evaluación de la exactitud del modelo con conjunto RGB. D) Pérdida obtenido con conjunto RGB.

Después de realizar el entrenamiento de cada uno de los modelos, registrando los pesos en cada una de las épocas de entrenamiento, se identificó en qué época cada modelo presentó el mejor desempeño (considerando el más alto porcentaje de exactitud y la menor pérdida del modelo en la fase de entrenamiento y validación); lo anterior se hizo debido a que después de que un modelo presenta su mejor desempeño, comienza a sobre ajustarse al conjunto de entrenamiento.

Al considerar los puntos previos para seleccionar el modelo con mejor desempeño, se encontró que el modelo entrenado con el conjunto en RGB presenta su mejor desempeño en su última época y el modelo entrenado en escala de grises en la época 197. En la Tabla 5.16, se reporta la evaluación de los modelos con mejor desempeño.

**Tabla 5. 16.** Evaluación del modelo VGG-16 con el conjunto de imágenes en crudo en EG y RGB.

Conjunto	Clases	Exactitud	Precisión	Sensibilidad	Valor-F1	Tiempo
Crudo EG	COVID-19	0.7353	0.6900	0.8000	0.7400	13 hrs,
	NOCVID-19		0.7900	0.6700	0.7300	22 min
Crudo RGB	COVID-19	0.7072	0.6700	0.8200	0.7400	11 hrs,
	NOCVID-19		0.7700	0.5900	0.6700	34 min

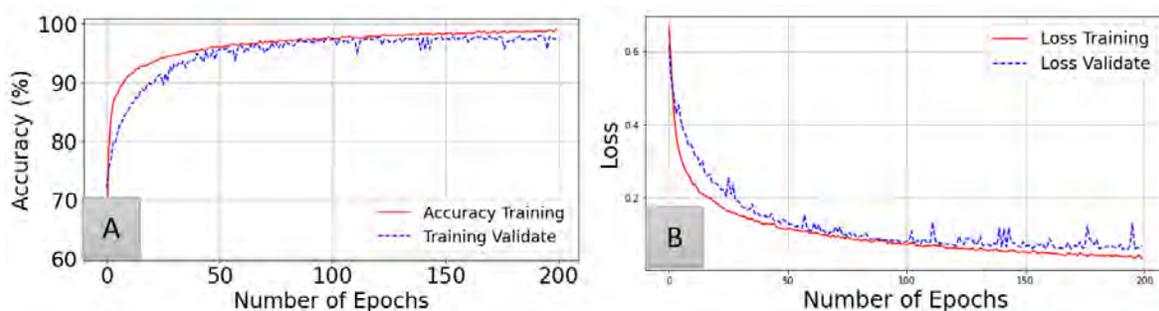
Analizando los resultados presentados en el proceso de evaluación se determinó, que se obtiene un mejor desempeño con el modelo que implementó el conjunto de imágenes en EG.

## 5.2.5 Experimentos con datos en crudo aplicando técnicas de filtrado

En esta experimentación se utilizó el conjunto de datos en crudo con la dimensionalidad en escala de grises y RGB, realizando la clasificación en las clases COVID-19 y NOCOVID-19, aplicando a estos conjuntos las técnicas de preprocesamiento de filtrado. Esta serie de experimentos consiste en implementar el conjunto de imágenes en crudo en la dimensionalidad de escala de grises y en RGB, aplicando las técnicas de filtrado para valorar si el modelo muestra un mejor desempeño al no aplicar la técnica de normalización de las imágenes. En cada uno de los experimentos se evaluó el desempeño de los modelos utilizando como métrica de evaluación *Accuracy* y la función de pérdida de entropía cruzada durante cada época. De esta manera, se determinó en cada modelo la época con mejor desempeño y consecuente se implementaron los pesos obtenidos para utilizarlos en la etapa de evaluación para el proceso de clasificación.

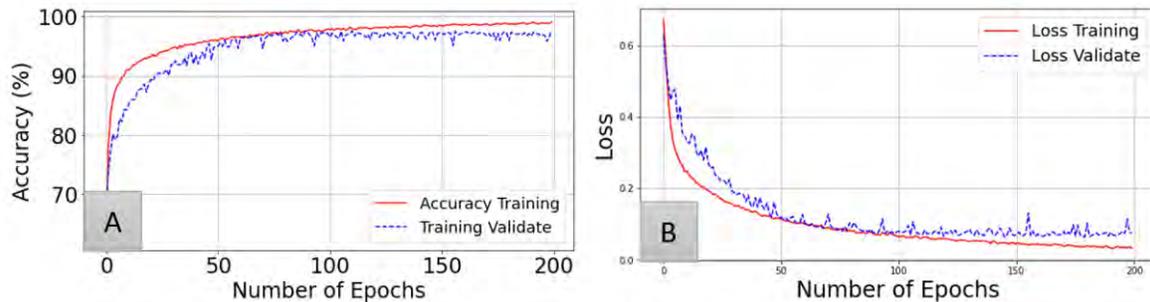
### Conjunto de datos en crudo aplicando la técnica de filtrado BCET

En la Figura 5.3 se puede observar el desempeño del modelo VGG-16 utilizando el conjunto de datos en crudo aplicando la Técnica de Filtrado BCET en EG, presentando un desempeño óptimo en la época 181.



**Figura 5. 3.** Desempeño del modelo implementando el conjunto de imágenes en crudo con la técnica de filtrado de BCET en EG. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento.

Consecuente se realizó la experimentación con el conjunto filtrado con la técnica BCET en RGB; en la Figura 5.4 se puede observar el desempeño del modelo, teniendo su mejor desempeño durante su última época de entrenamiento.



**Figura 5. 4.** Desempeño del modelo implementando el conjunto de imágenes en crudo con la técnica de filtrado de BCET en RGB. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento.

En la Tabla 5.17, se observa la evaluación de los modelos con mejor desempeño previamente obtenidos con los datos en crudo filtrados con la técnica BCET, considerando el conjunto en EG y en RGB.

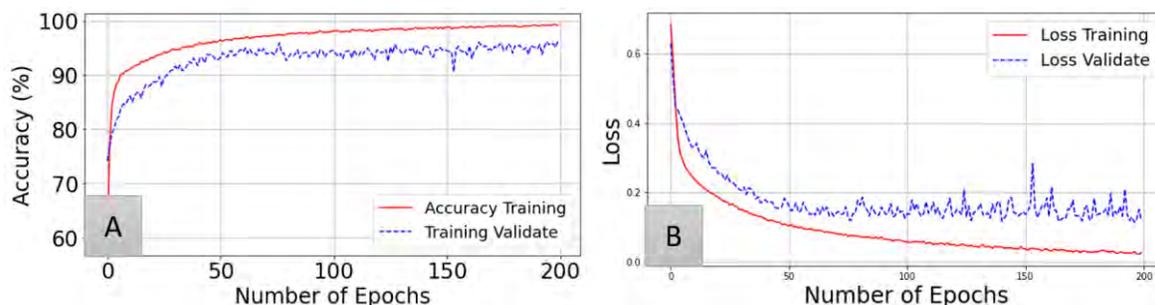
**Tabla 5. 17.** Evaluación del modelo VGG-16 con el conjunto de imágenes en crudo en EG y RGB implementando la técnica de filtrado BCET.

Conjunto	Clases	Exactitud	Precisión	Sensibilidad	Valor-F1	Tiempo
Crudo EG	COVID-19	0.7162	0.6700	0.8400	0.7500	8 hrs, 31 min
	NOCVID-19		0.7900	0.5900	0.6800	
Crudo RGB	COVID-19	0.7244	0.9722	0.4620	0.6264	9 hrs, 7 min
	NOCVID-19		0.6472	0.9868	0.7817	

Lo anterior demuestra que el implementar técnicas de filtrado con el conjunto de datos en crudo realmente no ayuda a mejorar el desempeño del modelo; podría ser que esta situación se debe al que al implementar imágenes en crudo se encuentran en ella objetos médicos o simbología que corresponde al dispositivo de adquisición.

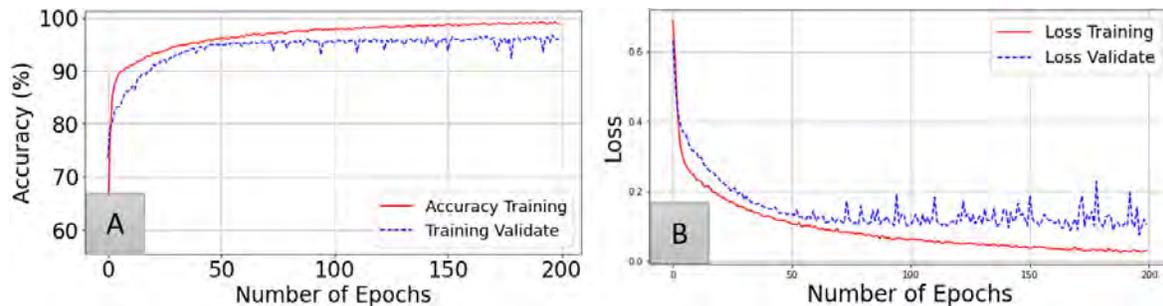
## Conjunto de datos en crudo aplicando la técnica de filtrado CLAHE

Continuando con la experimentación, se implementó el conjunto de datos en crudo en escala de grises filtrado con la técnica CLAHE, se observa su desempeño en la Figura 5.5.



**Figura 5. 5.** Desempeño del modelo implementando el conjunto de imágenes en crudo con la técnica de filtrado de CLAHE en EG. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento.

En la Figura 5.6 se presenta el desempeño obtenido por el modelo durante el entrenamiento con el conjunto de datos en crudo en RGB filtrado con la técnica CLAHE. Se determinó que el modelo presenta su mejor rendimiento en la época 194.



**Figura 5. 6.** Desempeño del modelo implementando el conjunto de imágenes en crudo con la técnica de filtrado de CLAHE en RGB. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenida durante el entrenamiento.

En la Tabla 5.18, se observa la evaluación de los modelos con mejor desempeño con datos en crudo filtrados con la técnica CLAHE, considerando el conjunto en EG y en RGB.

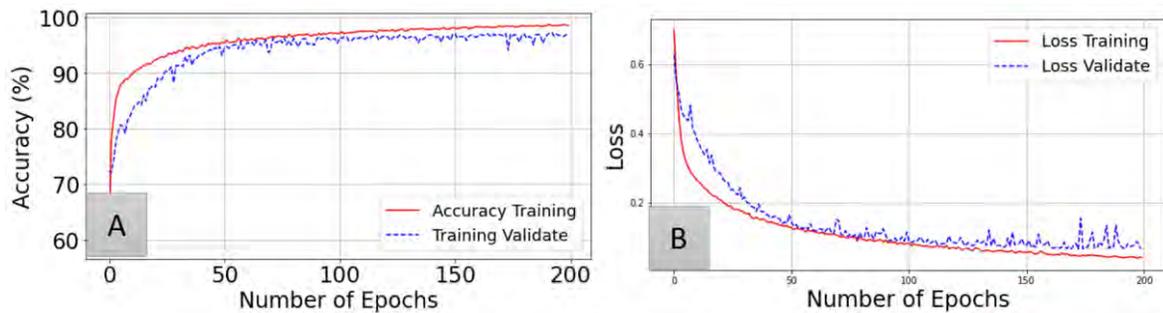
**Tabla 5. 18.** Evaluación del modelo VGG-16 con el conjunto de imágenes en crudo implementando la técnica de filtrado CLAHE en EG y RGB.

Conjunto	Clases	Exactitud	Precisión	Sensibilidad	Valor-F1	Tiempo
Crudo EG	COVID-19	0.7318	0.6512	0.9983	0.7883	11 hrs, 14 min
	NOCOVID-19		0.9965	0.4653	0.6344	
Crudo RGB	COVID-19	0.7723	0.6937	0.9752	0.8107	8 hrs, 37 min
	NOCOVID-19		0.9583	0.5693	0.7143	

Como se puede deducir de la tabla anterior, tanto al implementar esta técnica de filtrado como la anterior el desempeño del modelo es mermado por la condición de la presencia de objetos en el conjunto de datos implementados.

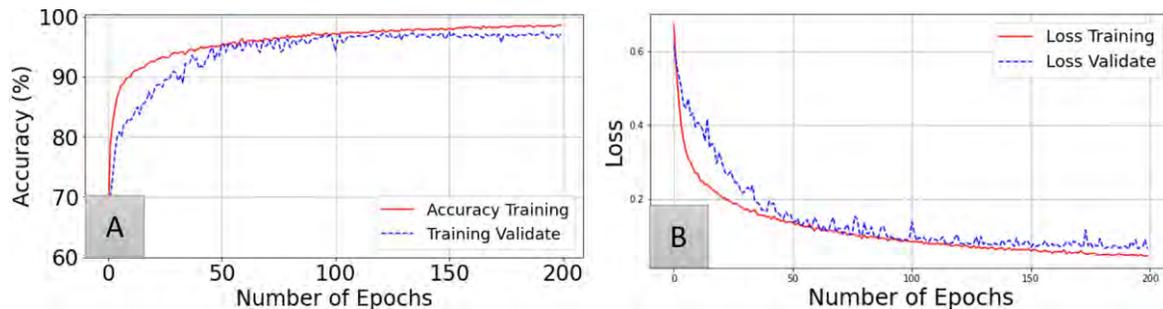
### Conjunto de datos en crudo aplicando la técnica de filtrado Gamma

Nuevamente se realizó un entrenamiento, pero ahora con el conjunto en crudo filtrado con la técnica de Gamma en EG, mostrando su desempeño en la Figura 5.7. El modelo presenta un rendimiento eficiente durante su última época de entrenamiento.



**Figura 5. 7.** Desempeño del modelo implementando el conjunto de imágenes en crudo con la técnica de filtrado de Gamma en EG. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenida durante el entrenamiento.

Posteriormente se utilizó la técnica de filtrado con el conjunto RGB; en la Figura 5.8, se puede observar que el modelo tuvo su mejor desempeño en la época 197. Los resultados de la evaluación del modelo se muestran en la Tabla 5.19.



**Figura 5. 8.** Desempeño del modelo implementando el conjunto de imágenes en crudo con la técnica de filtrado de Gamma en RGB. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenida durante el entrenamiento.

**Tabla 5. 19.** Evaluación del modelo VGG-16 con el conjunto de imágenes en crudo implementando la técnica de filtrado Gamma en EG y RGB.

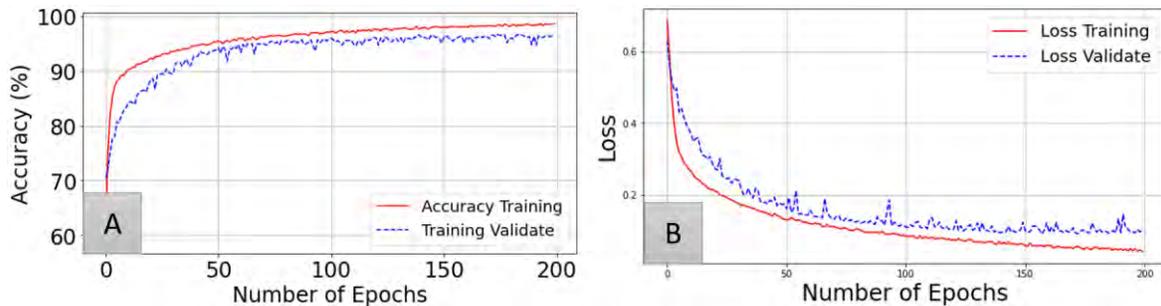
Conjunto	Clases	Exactitud	Precisión	Sensibilidad	Valor-F1	Tiempo
Crudo EG	COVID-19	0.5693	0.5380	0.9818	0.6951	9 hrs, 31 min
	NOCOVID-19		0.8962	0.1568	0.2669	
Crudo RGB	COVID-19	0.7360	0.6582	0.9818	0.7881	5 hrs, 07 min
	NOCOVID-19		0.9643	0.4901	0.6499	

Igual que con las experimentaciones previas se observa el reducido desempeño al implementar este conjunto de datos, en comparativa con el implementar las técnicas de filtrado en conjuntos con la técnica de normalización de las imágenes.

### Conjunto de datos en crudo aplicando la técnica de filtrado NCLAHE

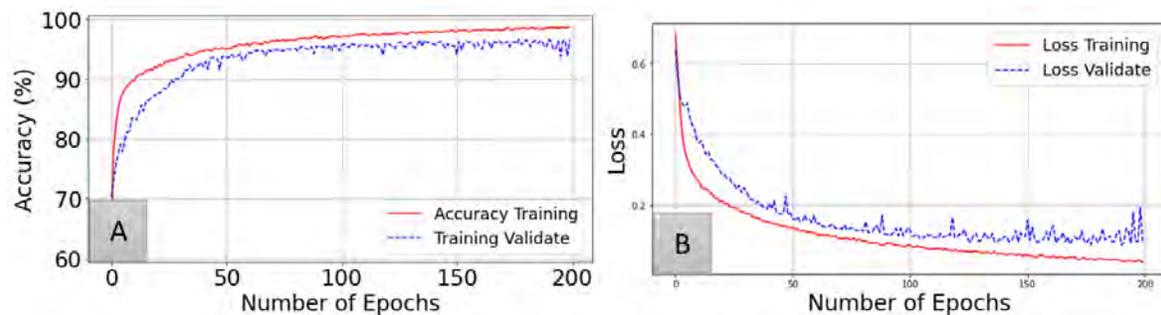
Se realizó el entrenamiento con el conjunto en crudo filtrado con la técnica NCLAHE en EG, observando su desempeño en la Figura 5.9. En el registro se observó que el

modelo presenta un buen rendimiento en la última época de entrenamiento, teniendo como resultados los mostrados en la Tabla 5.20.



**Figura 5. 9.** Desempeño del modelo implementando el conjunto de imágenes en crudo con la técnica de filtrado de NCLAHE en EG. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento.

Consecutivamente se experimentó con la misma configuración, pero con el conjunto en crudo filtrado con la técnica NCLAHE y posteriormente transformado en RGB, observando su desempeño en la Figura 5.10.



**Figura 5. 10.** Desempeño del modelo implementando el conjunto de imágenes en crudo con la técnica de filtrado de NCLAHE en RGB. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento.

**Tabla 5. 20.** Evaluación del modelo VGG-16 con el conjunto de imágenes en crudo implementando la técnica de filtrado NCLAHE en EG y RGB.

Conjunto	Clases	Exactitud	Precisión	Sensibilidad	Valor-F1	Tiempo
Crudo EG	COVID-19	0.7830	0.7001	0.9901	0.8202	10 hrs, 35 min
	NOCVID-19		0.9831	0.5759	0.7263	
Crudo RGB	COVID-19	0.7228	0.6442	0.9950	0.7821	9 hrs, 3 min
	NOCVID-19		0.9891	0.4505	0.6190	

Nuevamente, no se presentó un desempeño adecuado del modelo durante la etapa de prueba.

## 5.2.6 Sintonización de la técnica de Filtrado CLAHE del modelo VGG-16

Debido al buen desempeño del modelo al implementar la técnica de preprocesamiento de filtrado CLAHE, se realizó una nueva experimentación con la diferencia que se realizó una nueva distribución del conjunto de datos normalizado designando para entrenamiento a un 80%, pero reduciendo los subconjuntos de validación y prueba en un 10% cada uno, siendo observado este conjunto en la Tabla 5.21.

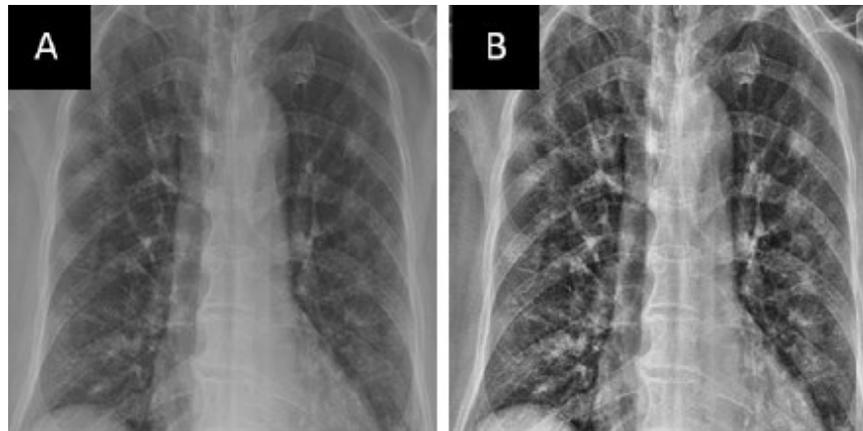
Después de realizar el aumento del conjunto de entrenamiento de datos normalizado se procedió de nueva cuenta el realizar el proceso de sintonización de la técnica de filtrado CLAHE; en este apartado se observa el proceso realizado para esta sintonización. En este proceso de experimentación se implementó el tamaño de lotes a implementar es de 32 imágenes y el porcentaje del 30% en la técnica de abandono.

**Tabla 5. 21.** Aumento del conjunto de imágenes de radiografías de tórax normalizado.

Clases de las patologías	Entrenamiento (80%)	Validación (10%)	Prueba (10%)
COVID-19	2,671	333	333
NOCVID-19	2,671	333	333

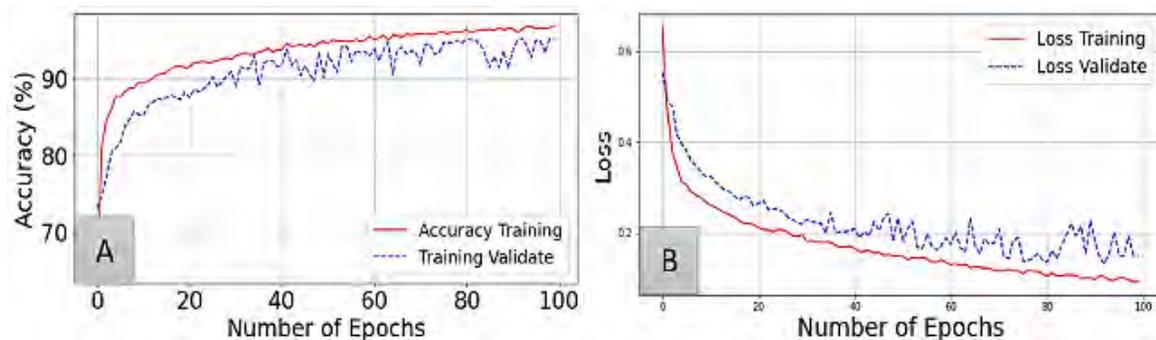
### Conjunto de datos con nueva distribución aplicada la configuración estándar de la Técnica de Filtrado CLAHE

En esta prueba se implementó la técnica de filtrado CLAHE, la cual consiste en dividir la imagen en mosaicos pequeños y ecualizar cada uno para controlar la dispersión de los valores de intensidad. Para evitar la amplificación del ruido, se aplica una limitación de contraste, recortando los píxeles que superen un umbral y distribuyéndolos uniformemente. Tras la ecualización, se utiliza interpolación bilineal para eliminar artefactos en los bordes. El resultado se muestra en una radiografía de un paciente con COVID-19 usando la configuración estándar (Singh, 2021). En la Figura 5.11, se puede observar el preprocesamiento realizado a una radiografía de un paciente con COVID-19.



**Figura 5. 11.** Radiografía de tórax positivo a COVID-19 A) Imagen en crudo. B) Radiografía aplicando filtro CLAHE.

Mediante la configuración estándar de la técnica de filtrado, se realizó una nueva experimentación utilizando el nuevo conjunto de imágenes ampliando en el subconjunto de entrenamiento. Se implementó la configuración del modelo propuesta previamente mencionada, pudiendo observar el mejor desempeño en la Figura 5.12.



**Figura 5. 12.** Desempeño del modelo implementando el conjunto con nueva distribución de las imágenes normalizado y aplicada la técnica de filtrado de CLAHE estándar. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenida durante el entrenamiento.

Mediante el análisis del desempeño durante el entrenamiento, se determinó que el modelo presentó su mejor rendimiento en la época 93; consecuente se implementó los pesos obtenidos y se realizó la prueba del modelo con el conjunto de pruebas, siendo estas imágenes que la red nunca ha visto. En la Tabla 5.22, se puede observar los resultados obtenidos con este modelo.

**Tabla 5. 22.** Evaluación del modelo VGG-16 con el conjunto normalizado implementando Filtrado la CLAHE.

Casilla	Umbral	Clases	Exactitud	Precisión	Sensibilidad	Valor-F1	Tiempo
8×8	2.0	COVID-19	0.8544	0.8500	0.8600	0.8600	4 hrs, 10min
		NOCVID-19		0.8600	0.8500	0.8500	

Debido a que se obtuvo un mejor desempeño por parte del modelo con la nueva distribución del conjunto normalizado aplicado con la técnica de filtrado CLAHE durante la etapa de prueba, además de obtener un menor consumo computacional (tiempo de ejecución), se procedió a realizar la sintonización de la técnica de filtrado CLAHE.

### Sintonización de la Técnica de Filtrado CLAHE implementando el conjunto de datos ampliado

El proceso de sintonización de la técnica de filtrado CLAHE, consiste en modificar el tamaño de la casilla que recorre la imagen para realizar la ecualización del histograma en cada casilla y el umbral de limitación de contraste. El proceso de sintonización se realizó mediante la implementación de diferentes configuraciones de la técnica de filtrado CLAHE al conjunto de datos normalizados ampliado, consecuente se experimentaron con este nuevo conjunto para determinar la sintonización más adecuada para el modelo para presentar un mejor desempeño durante la etapa de evaluación de este. En la Tabla 5.23 y 5.24, se puede observar el rendimiento mostrado durante el proceso de sintonización.

**Tabla 5. 23.** Sintonización del modelo VGG-16 con el conjunto de imágenes normalizado ampliado con filtrado CLAHE.

Casilla	Umbral	Clases	Exactitud	Precisión	Sensibilidad	Valor-F1	Tiempo
2×2	2.0	COVID-19	0.6997	0.6600	0.8100	0.7300	3 hrs, 42 min
		NOCOVID-19		0.7600	0.5900	0.6600	
4×4	2.0	COVID-19	0.7012	0.7500	0.6000	0.6700	4 hrs, 3 min
		NOCOVID-19		0.6700	0.8000	0.7300	
8×8	2.0	COVID-19	0.8261	0.8991	0.7346	0.8086	4 hrs, 11 min
		NOCOVID-19		0.8374	0.8261	0.8246	
16×16	2.0	COVID-19	0.6727	0.6800	0.6500	0.6700	3 hrs, 49 min
		NOCOVID-19		0.6700	0.6900	0.6800	
2×2	3.0	COVID-19	0.7342	0.7500	0.7100	0.7300	3 hrs, 47 min
		NOCOVID-19		0.7200	0.7600	0.7400	
4×4	3.0	COVID-19	0.8574	0.9722	0.7357	0.8376	3 hrs, 11 min
		NOCOVID-19		0.7874	0.9790	0.8728	
8×8	3.0	COVID-19	0.8964	0.9100	0.8800	0.8900	3 hrs, 37 min
		NOCOVID-19		0.8800	0.9200	0.9000	
		NOCOVID-19		0.7500	0.3700	0.4900	

**Tabla 5. 24.** Sintonización del modelo VGG-16 con el conjunto de imágenes normalizado ampliado con filtrado CLAHE (continuación).

Casilla	Umbral	Clases	Exactitud	Precisión	Sensibilidad	Valor-F1	Tiempo
16×16	3.0	COVID-19	0.7057	0.7300	0.6500	0.6900	3 hrs, 57 min
		NOCOVID-19		0.6900	0.7600	0.7200	
2×2	4.0	COVID-19	0.6306	0.6400	0.6100	0.6200	4 hrs, 11 min
		NOCOVID-19		0.6200	0.6500	0.6400	
4×4	4.0	COVID-19	0.6411	0.6800	0.5400	0.6000	3 hrs, 41 min
		NOCOVID-19		0.6200	0.7400	0.6700	
8×8	4.0	COVID-19	0.6907	0.6178	1.0000	0.7638	3 hrs, 43 min
		NOCOVID-19		1.0000	0.3814	0.5522	
16×16	4.0	COVID-19	0.6216	0.5800	0.8700	0.7000	3 hrs, 48 min
		NOCOVID-19		0.7500	0.3700	0.4900	

Al realizar el proceso de sintonización de la técnica de filtrado, se obtuvo un mejor desempeño al implementar la configuración de 8×8 con un umbral de 3.0; además, de mostrar un aumento en las métricas de predicción del modelo se presentó una reducción en los tiempos de entrenamiento, demostrando un menor consumo computacional.

## 5.2.7 Sintonización de hiperparámetros del modelo de Red Neuronal Convolutiva propuesto

En este proceso de sintonización, se implementó como base la configuración inicial presentada en las primeras series de experimentaciones por el buen desempeño que presentó la configuración. La actividad está conformada por una serie de experimentos que pretenden mejorar el rendimiento del modelo, para esto se requirió realizar experimentaciones para evaluar si el cambio de los hiperparámetros del modelo de aprendizaje VGG-16, realmente mejora el desempeño del modelo.

### Experimentación de Optimizador

El realizar la sintonización de un modelo de Red Neuronal Convolutiva requiere una profunda experimentación con una gran variedad de hiperparámetros, entre estos parámetros se encuentran los optimizadores que realizan la tarea de optimizar los valores de los parámetros para reducir el error cometido por la red, el tiempo en que el optimizador reduzca el error durante la fase de entrenamiento depende del valor de la tasa de aprendizaje a implementar, el valor predeterminado para el factor de aprendizaje es del 0.001, siendo este implementado en la experimentación.

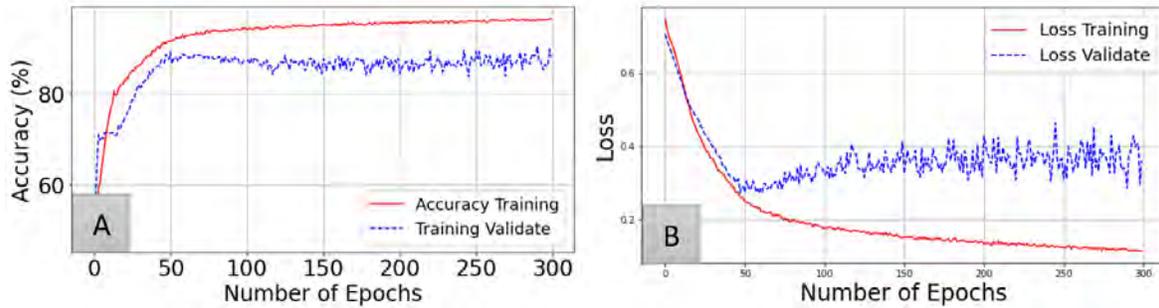
En este trabajo de investigación se implementaron para evaluación los métodos de optimización disponibles en la librería de *Keras*, siendo estos el *Stochastic Gradient Descent (SGD)*, *Root Mean Square Propagation (RMSprop)*, *Adaptive moment estimation (Adam)*, *Adadelta*, *Adaptive Gradient Algorithm (AdaGrad)*, *Adamax*, *Nadam* y *Ftrl*. En esta experimentación se utilizó configuración de entorno y del modelo previamente establecido, únicamente se diferenció con el tamaño de lotes siendo este de 32 imágenes. Los resultados obtenidos se observan en la Tabla 5.25.

**Tabla 5. 25.** Sintonización del hiperparámetro del optimizador del modelo VGG-16 con el conjunto de imágenes normalizado nuevo con filtrado CLAHE.

Optimizador	Clases	Exactitud	Precisión	Sensibilidad	Valor-F1	Tiempo
SGD	COVID-19	0.6306	0.6200	0.6600	0.6400	4 hrs, 47 min
	NOCOVID-19		0.6400	0.6000	0.6200	
RMSprop	COVID-19	0.5240	0.5200	0.7700	0.6200	4 hrs, 54 min
	NOCOVID-19		0.5500	0.2800	0.3700	
Adam	COVID-19	0.7883	0.7162	0.9550	0.8185	3 hrs, 41 min
	NOCOVID-19		0.9324	0.6216	0.7459	
AdaGrad	COVID-19	0.7042	0.6800	0.7700	0.7200	5 hrs, 17 min
	NOCOVID-19		0.7400	0.6400	0.6800	
Adamax	COVID-19	0.7538	0.7600	0.7400	0.7500	3 hrs, 34 min
	NOCOVID-19		0.7500	0.7600	0.7600	
Nadam	COVID-19	0.5098	0.4900	0.8500	0.6200	3 hrs, 42 min
	NOCOVID-19		0.6200	0.2100	0.3100	
Ftrl	COVID-19	0.4474	0.4700	0.4700	0.7400	4 hrs, 4 min
	NOCOVID-19		0.4474	0.3800	0.1600	
Adadelta	COVID-19	0.8964	0.9100	0.8800	0.8900	3 hrs, 37 min
	NOCOVID-19		0.8800	0.9200	0.9000	

## Implementación de mayor cantidad de épocas

Se realizó una experimentación con la configuración predeterminada en la sección de experimento 1, con la diferencia de que se implementó un 30% en la técnica de abandono del modelo y se utilizaron 300 épocas de entrenamiento utilizando el optimizador *Adadelta* con un factor de aprendizaje del 0.0001; para observar el rendimiento del modelo en el entrenamiento. En la Figura 5.13, se puede observar el rendimiento durante el entrenamiento del modelo y el análisis del mejor desempeño obtenido por el modelo durante la fase de entrenamiento.



**Figura 5. 13.** Desempeño del modelo implementando el conjunto de imágenes normalizado ampliado con la técnica de filtrado de CLAHE. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento.

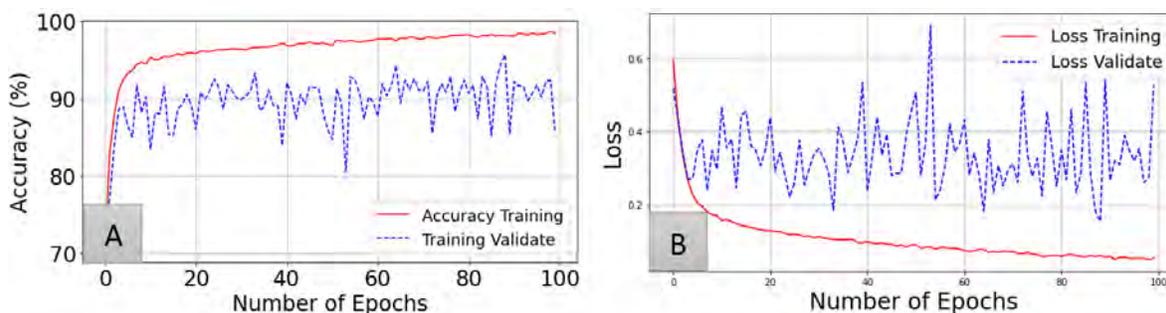
Se observa que el implementar un factor de aprendizaje bajo, se presenta que el modelo no mejora su desempeño durante el entrenamiento y la exactitud en su predicción es muy baja para presentar una generalización adecuada entre clases. Mostrando sus resultados en la Tabla 5.26.

**Tabla 5. 26.** Sintonización del hiperparámetros del modelo VGG-16 con el conjunto normalizado aplicando la técnica CLAHE utilizando 300 época de entrenamiento.

Clases	Exactitud	Precisión	Sensibilidad	Valor-F1	Tiempo
COVID-19	0.7598	0.9943	0.5225	0.6850	4 hrs, 22 min
NOCOVID-19		0.6762	0.9970	0.8058	

## Implementación de diferentes técnicas de aumento de datos

Para esta experimentación se utilizó la configuración predeterminada en el experimento 1 con la diferencia de que se implementó un 30% en la técnica de abandono del modelo, utilizando 100 épocas de entrenamiento y se modificó el apartado del aumento de datos el rango de rotación en  $10^\circ$  y un aumento del 10%. En la Figura 5.14, se puede observar el desempeño obtenido por el modelo durante la fase de entrenamiento.



**Figura 5. 14.** Desempeño del modelo implementando el conjunto de imágenes normalizado con la técnica de filtrado de CLAHE. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento.

Al realizar el análisis del modelo durante la fase de entrenamiento, se determinó que el modelo presenta su mejor desempeño en la época 87, se procedió a implementar

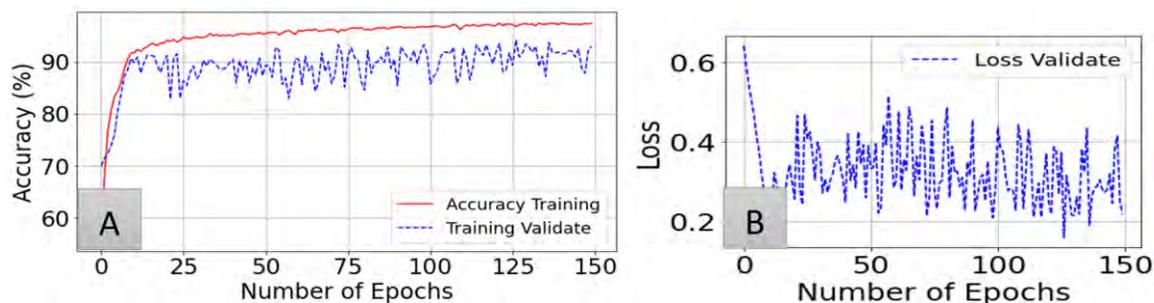
los pesos del entrenamiento del modelo presentan un desempeño considerable sin igualar el resultado previo del modelo al utilizar Adadelta. Observándose su resultado en la Tabla 5.27.

**Tabla 5. 27.** Sintonización del hiperparámetro del modelo VGG-16 con el conjunto de imágenes normalizado ampliado con 100 época de entrenamiento.

Clases	Exactitud	Precisión	Sensibilidad	Valor-F1	Tiempo
COVID-19	0.8634	0.8040	0.9610	0.8755	3 hrs, 42 min
NOCVID-19		0.9515	0.7658	0.8486	

## Implementación de aumento del tamaño de lotes

En esta experimentación se utilizó la configuración predeterminada en la experimentación 1, con la diferencia de que se implementó un 30% en la técnica de abandono del modelo, 150 épocas de entrenamiento y un tamaño de lote de 128 imágenes. En la Figura 5.15, se puede observar el desempeño del entrenamiento del modelo y el análisis de la menor pérdida obtenida por el modelo durante la fase de entrenamiento en la época 126.



**Figura 5. 15.** Desempeño del modelo implementando el conjunto de imágenes normalizado ampliado con la técnica de filtrado de CLAHE. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenida durante el entrenamiento.

Se observa que el implementar un factor de aprendizaje bajo, se presenta que el modelo no mejora su desempeño durante el entrenamiento y la exactitud en su predicción se inclina a una de las clases para presentar una generalización adecuada entre clases. Mostrando su efectividad de predicción en la Tabla 5.28.

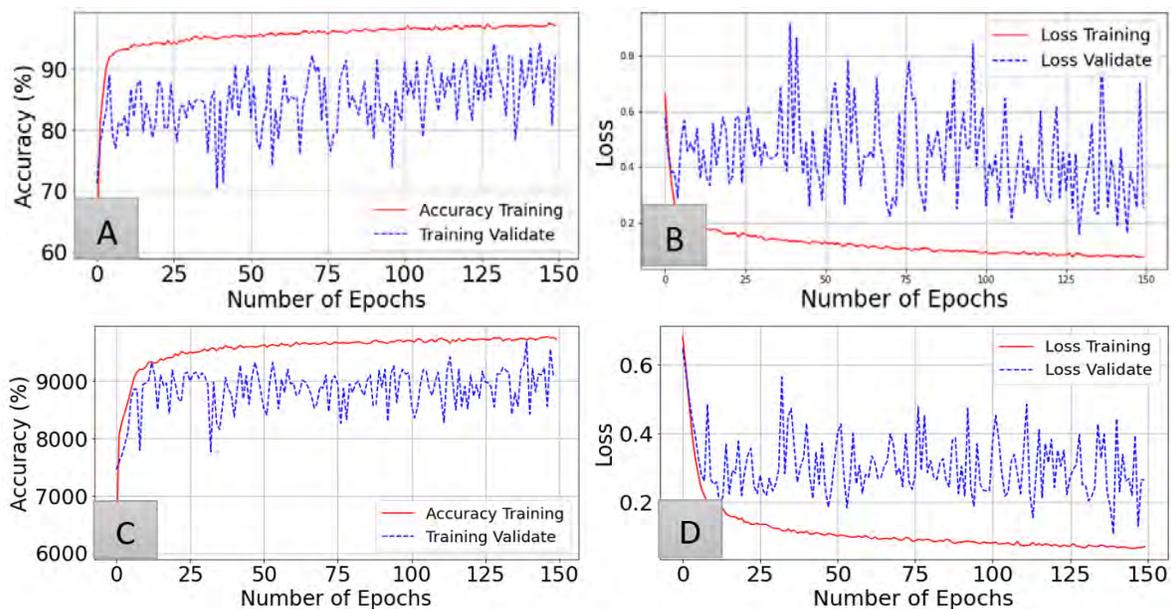
**Tabla 5. 28.** Sintonización del del modelo VGG-16 con el conjunto de imágenes normalizado ampliado con 150 época de entrenamiento.

Clases	Exactitud	Precisión	Sensibilidad	Valor-F1	Tiempo
COVID-19	0.8378	0.9800	0.6900	0.8100	5 hrs, 31 min
NOCVID-19		0.7600	0.9900	0.8600	

## Implementación de técnica Flip de aumento de datos

Para esta experimentación se utilizó la configuración predeterminada en experimentaciones previas; con la diferencia de que se implementó un 30% en la técnica de abandono del modelo, además se implementaron 150 épocas de entrenamiento utilizando un tamaño de lote de 32 y 128 imágenes, además se utilizó el aumento de las imágenes mediante la técnica de *Flip* horizontal y vertical; durante la implementación de estas configuraciones se puso en duda si presentara un buen desempeño el modelo ante esta configuración debido a la posición del corazón presentada en la radiografía de tórax, considerando que le generaría a la red datos atípicos.

En la Figura 5.16, se puede observar el desempeño de los entrenamientos del modelo y el análisis de la pérdida obtenido por ambos experimentos durante la fase de entrenamiento; determinando que el primer modelo se obtuvo mejores resultados en la época 127 y en el segundo modelo la época 139.



**Figura 5. 16.** Desempeño del modelo implementando el conjunto de imágenes normalizado aplicado filtro CLAHE e implementa la técnica FLIP teniendo como tamaño de lote el de 32 y 128.

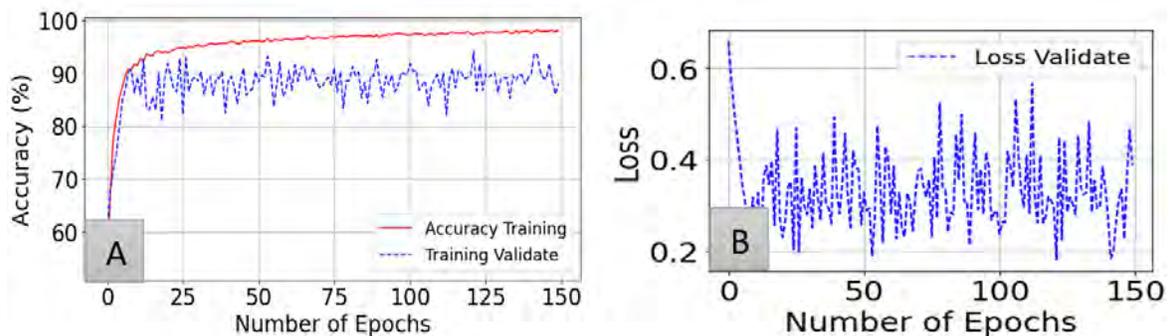
Aunque se implementó el modelo con los pesos de mejor rendimiento; debido a la técnica de aumento denominada como Flip, el modelo que utilizó el tamaño de lotes de 32 imágenes, presentó un desempeño poco favorable, pero se debe destacar que al implementar el tamaño de lote de 128 el modelo permite clasificar mejor las imágenes a cambio de un mayor costo computacional debido al aumento de entrenamiento. Presentando su efectividad en la Tabla 5.29.

**Tabla 5. 29.** Modelo VGG-16 implementando la técnica de aumento de datos Flip.

Clases	Exactitud	Precisión	Sensibilidad	Valor-F1	Tiempo entrenamiento
COVID-19	0.6652	1.0000	0.3303	0.4966	3 hrs, 52 min
NOCOVID-19		0.5989	1.0000	0.7492	
COVID-19	0.8108	0.7358	0.9700	0.8368	4 hrs, 24 min
NOCOVID-19		0.9559	0.6517	0.7750	

## Implementación de diferentes técnicas de aumento de datos con un tamaño de lotes de 128 imágenes

Para esta experimentación se utilizó la configuración predeterminada en experimentaciones previas; con la diferencia de que se implementó un 20% en la técnica de abandono del modelo, además se implementaron 150 épocas de entrenamiento utilizando un tamaño de lote de 128 imágenes, además se utilizó un diferente rango de aumento 10% y un ángulo de rotación de 10°. En la Figura 5.17, se puede observar el desempeño del entrenamiento del modelo, determinando que el modelo se desempeña mejor en la época 141.



**Figura 5. 17.** Desempeño del modelo implementando el aumento de datos con tamaño de lote de 128 imágenes. A) Evaluación de la exactitud del modelo durante el entrenamiento. B) Pérdida obtenido durante el entrenamiento.

Pudiéndose observar en la Tabla 5.30, el resultado de experimentación durante el proceso de clasificación.

**Tabla 5. 30.** Modelo VGG-16 implementando un tamaño de lotes de 128 imágenes.

Clases	Exactitud	Precisión	Sensibilidad	Valor-F1	Tiempo entrenamiento
COVID-19	0.8453	0.8343	0.8619	0.8479	4 hrs, 52 min
NOCOVID-19		0.8571	0.8288	0.8427	

## Implementación de un tamaño de lotes de 128 imágenes en 200 épocas de entrenamiento

En este experimento se utilizó la configuración predeterminada en experimentaciones previas a excepción se utilizó un tamaño de lotes de 128 imágenes con 200 épocas de entrenamiento con los datos normalizado y con un 20% de abandono. En la Tabla 5.31, se observa el resultado obtenido al implementar esta sintonización del modelo.

**Tabla 5. 31.** Modelo VGG-16 implementando un tamaño de lotes de 128 imágenes y 200 épocas.

Clases	Exactitud	Precisión	Sensibilidad	Valor-F1	Tiempo entrenamiento
COVID-19	0.8919	0.9307	0.8468	0.8868	4 hrs, 31 min
NOCVID-19		0.8595	0.9369	0.8966	

## Implementación de un tamaño de lotes de 128 imágenes en 150 épocas de entrenamiento e integrando 2 ultimas capas totalmente conectadas de 512 neuronas

En este experimento se utilizó la configuración predeterminada en experimentaciones previas a excepción se utilizó un tamaño de lotes de 128 imágenes con 150 épocas de entrenamiento con los datos normalizado, con un 20% de abandono y las ultimas 2 capas totalmente conectadas presentando 512 neuronas cada una. En la Tabla 5.32, se observa el resultado obtenido al implementar esta sintonización del modelo.

**Tabla 5. 32.** Modelo VGG-16 implementando un tamaño de lotes de 128 imágenes y 512 neuronas.

Clases	Exactitud	Precisión	Sensibilidad	Valor-F1	Tiempo entrenamiento
COVID-19	0.7117	1.0000	0.4234	0.5949	5 hrs, 11 min
NOCVID-19		0.6343	1.0000	0.7762	

## Experimentación con arquitectura sintonizada

Después de realizar el complejo proceso de sintonización de la técnica de filtrado CLAHE y los hiperparámetros del modelo de Red Neuronal Convolutacional, se realizó una experimentación para evaluar los parámetros sintonizados.

## Base de datos implementada

Se utilizó el conjunto de datos normalizado y aplicando la técnica de filtrado CLAHE sintonizada (utilizando una casilla de  $8 \times 8$  y un umbral de 3), realizando la división del conjunto de imágenes 80% entrenamiento, 10% para validación y 10% para prueba, mostrado en la Tabla 5.33.

**Tabla 5. 33.** Conjunto de imágenes de radiografías de tórax normalizado y aplicado filtro CLAHE sintonizado.

Clases de las patologías	Entrenamiento (80%)	Validación (10%)	Prueba (10%)
COVID-19	2, 670	333	333
NOCOVID-19	2, 670	333	333

## Configuración de parámetros del entrenamiento

- ❖ Aumento de datos del conjunto de entrenamiento:
  - Acercamiento: 20% de acercamiento a la imagen.
  - Rotación: Un ángulo de rotación del 20%.
  - Desplazamiento: 10% de desplazamiento a lo alto y largo de la imagen.
- ❖ Dimensionalidad de las imágenes del  $224 \times 224 \times 3$
- ❖ 150 épocas de entrenamiento
- ❖ Tamaño del lote de 32 imágenes
- ❖ Modificación de las 2 últimas capas totalmente conectadas: 128 neuronas
- ❖ Abandono del 30%
- ❖ Optimizador Adadelta con un factor de aprendizaje 0.001
- ❖ Función de pérdida de Entropía cruzada binaria
- ❖ Función de clasificación softmax
- ❖ Transferencia de aprendizaje con el conjunto ImageNet
- ❖ Pesos implementados de la época 137.

## Resultados obtenidos

Al utilizar los parámetros con mejor rendimiento del proceso de sintonización, obtenemos un modelo que su desempeño resulta eficiente para la clasificación de COVID-19 y NOCOVID-19 en un entorno real, en la Tabla 5.34, se observa los resultados obtenidos con el modelo propuesto.

**Tabla 5. 34.** Experimento con modelo sintonizado y técnicas de preprocesamiento implementadas.

Clases	Exactitud	Precisión	Sensibilidad	Valor-F1	Tiempo entrenamiento
COVID-19	0.9009	0.8961	0.9069	0.9015	3 hrs, 28 min
NOCOVID-19		0.9058	0.8949	0.9003	

### 5.3 Informe de pruebas de modelo de aprendizaje propuesto

Después de realizar el procesamiento de las radiografías excluidas durante el proceso de normalización, estas imágenes fueron anexadas al conjunto normalizado y filtrado con la técnica CLAHE; se obtiene un nuevo conjunto, observándose en la Tabla 5.35.

**Tabla 5. 35.** Nuevo conjunto de imágenes de radiografías de tórax normalizado y aplicado filtro CLAHE sintonizado.

Clases de las patologías	Entrenamiento (80%)	Validación (10%)	Prueba (10%)
COVID-19	3, 019	377	377
NOCOVID-19	3, 019	377	377

Consecuente, se realizó un nuevo entrenamiento con el conjunto previamente mencionado, utilizando la configuración de los hiperparámetros de la arquitectura sintonizada, la configuración con mejor eficacia de la técnica de Filtrado CLAHE obtenida por la sintonización previamente realizada y utilizando los pesos de la época con mejor desempeño, siendo esta la 123 determinada por el análisis de las épocas del entrenamiento; pudiendo observar el rendimiento del modelo en la Tabla 5.36.

**Tabla 5. 36.** Experimento con modelo sintonizado y técnicas de preprocesamiento implementadas.

Clases	Exactitud	Precisión	Sensibilidad	Valor-F1	Tiempo entrenamiento
COVID-19	0.9234	0.9123	0.9369	0.9244	4 hrs, 35 min
NOCOVID-19		0.9352	0.9099	0.9224	
General		0.9237	0.9234	0.9234	

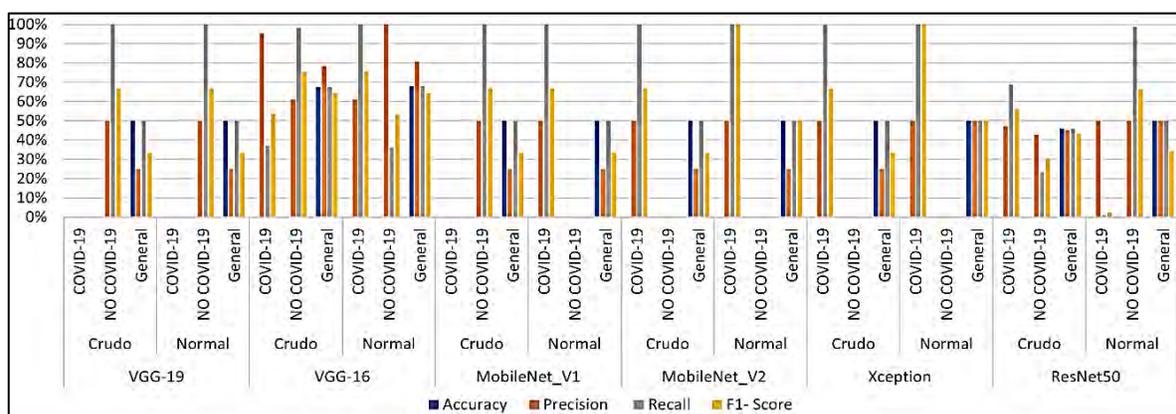
Obteniendo los mejores resultados del modelo de clasificación, concluyendo que la sintonización del modelo, técnica de filtrado CLAHE y el aumento del conjunto de datos implementando técnicas de preprocesamiento; logrando obtener un modelo capaz de ser implementado en un entorno real.

## 5.4 Discusión

La experimentación fue dividida en 7 fases, la primera fase de experimentación consistió en evaluar el desempeño de los modelos VGG-16, VGG-19, Xception, MobileNetV1, MobileNetV2 y ResNet50, al implementar la técnica de *freezing*, en esta prueba muestra que a pesar de implementar la cantidad de 50 épocas para entrenamiento y reentrenando la red completamente, se obtuvieron resultados factibles al no implementar la técnica de *freezing*; destacando el desempeño de la red VGG-16 en esta prueba en comparativas con los demás modelos. Debido a lo demostrado en la experimentación se estableció como estándar el únicamente realizar experimentaciones sin implementar la técnica de *freezing* de entrenamiento.

La segunda fase de experimentación utilizó el conjunto de imágenes recopilado en crudo, en el cual se estableció 50 épocas para entrenamiento y la configuración predeterminada de los hiperparámetros del modelo con un tamaño de lotes de 32 imágenes. Se demostró que el conjunto normalizado a pesar de ser de menor tamaño que el de datos en crudo; obtuvo una *Accuracy* (exactitud) no menor del 50% en cada uno de los modelos, demostrando que con el conjunto normalizado se obtuvo un mejor resultado en el proceso de discriminación.

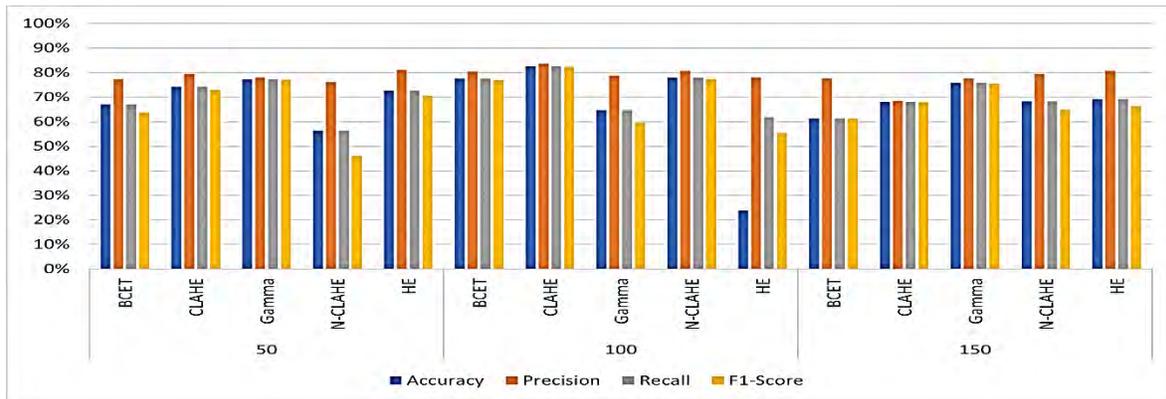
En la Figura 5.18 se observa los resultados obtenidos en esta experimentación, resaltando de esta serie de experimentos que el modelo VGG-16 presenta mejor desempeño, al presentar un *Accuracy* del 67.70% con datos en crudo y 68.07% normalizados, concluyendo que el modelo VGG-16 se adapta mejor a al conjunto de imágenes recopilado.



**Figura 5. 18.** Resultados obtenidos con datos en crudo y normalizado por los modelos de RNC.

La tercera fase de experimentación es evaluar el conjunto de imágenes normalizado COVID-TECNM (Reyes, et al., 2022) aplicando las Técnicas de Filtrado Ecuilización del Histograma (HE), Mejora de Contraste Equilibrado (BCET), Ecuilización Adaptativa del

Histograma Limitada por el Contraste (CLAHE), Corrección Gamma y NCLAHE; generando de esta forma una serie de 15 experimentos en los cuales se establecieron 50, 100 y 150 épocas de entrenamiento, para evaluar el desempeño del modelo VGG-16 al aplicar dichos filtros. En la Figura 5.19, se puede observar los resultados generales obtenidos en cada una de las métricas evaluadas.



**Figura 5. 19.** Resultados obtenidos por VGG-16 con datos normalizados y técnicas de preprocesamiento.

Con base a los desempeños obtenidos del modelo VGG-16 al implementar la técnica de normalización y las técnicas de filtrado en conjunto mostrados en la Figura 5.19, se concluye que se presenta un mejor rendimiento a partir de 50 épocas de entrenamiento en comparativa a implementar datos en crudo o únicamente la Técnica de Normalización. Utilizando las Técnicas de Filtrado CLAHE, Gamma y HE; se obtuvo una exactitud del 74.21%, 77.29% y 81.17%, respectivamente. En 100 épocas de entrenamiento, se observó que el desempeño mejoró al utilizar las técnicas BCET, CLAHE y NCLAHE; destacando el aplicar la técnica de filtrado CLAHE, mediante el cual se obtuvo un 82.61% de exactitud.

La cuarta fase de experimentación consistió en implementar el conjunto de datos en crudo con las clases COVID-19 y NOCOVID-19 en 2 tipos de dimensiones, siendo esta en 3 canales (RGB) y en un solo canal (escala de grises), pero con una mayor cantidad de épocas de entrenamiento; donde se observó el desempeño del modelo VGG-16 para determinar si el modelo demostraba un rendimiento efectivo sin implementar las técnicas de preprocesamiento de filtrado y normalización.

Se realizó el entrenamiento de cada uno de los modelos y mediante el registro de los pesos en cada una de las épocas de entrenamiento; se demostró que el modelo entrenado con el conjunto en RGB presenta su mejor desempeño en su última época y el modelo entrenado en escala de grises en la época 197 antes de presentar sobre ajuste en ambos modelos. Se determinó, que se obtiene un mejor rendimiento en el modelo que implemento el conjunto de imágenes en EG obtuvo de resultados Exactitud 73.53% y el conjunto en RGB 70.72%.

Analizando los resultados obtenidos se demuestra que el modelo presentó un desempeño factible al aumentar la cantidad de épocas de entrenamiento con datos en crudo, pero al no presentar mayor mejora en la clasificación al aumentar la cantidad de épocas con datos en crudos; se procedió a implementar técnicas de preprocesamiento de filtrado para observar su rendimiento, considerando como estándar de entrenamiento implementar una mayor cantidad de épocas y experimentar con el conjunto de datos pero en los dos tipos de dimensiones.

En la quinta fase de experimentación se implementó el conjunto de datos en crudo con la dimensionalidad de imágenes en escala de grises y color (RGB), realizando la clasificación en las clases COVID-19 y NOCOVID-19, aplicando a estos conjuntos técnicas de preprocesamiento de filtrado. Se evaluó el desempeño de los modelos utilizando como métrica de evaluación Exactitud y la función de pérdida de entropía cruzada durante cada época. De esta manera, se determinó en cada modelo la época con mejor desempeño y consecuente se implementaron los pesos para utilizarlos en la etapa de evaluación para el proceso de clasificación. Destacando dos modelos por los resultados obtenidos en la evaluación, siendo estos: el modelo VGG-16 implementando el conjunto de datos en crudo con dimensionalidad en escala de grises y aplicada la técnica de NCLAHE obtuvo una Exactitud del 78.30%; y el modelo VGG-16 implementando el conjunto de datos en crudo con dimensionalidad en color y aplicada la técnica de CLAHE que obtuvo. Demostrando que al implementar técnicas de filtrado se apoyó al modelo a obtener un mejor desempeño. Desafortunadamente si se aumenta las épocas de entrenamiento el modelo se sobre ajusta obteniendo predicciones no factibles.

En la sexta fase de experimentación se realizó la sintonización de la Técnica de Filtrado CLAHE por su fiable desempeño en la predicción durante las previas fases de experimentación. Para la sintonización se implementó el conjunto de datos ampliado y se modificó el tamaño de la casilla que recorre la imagen y el umbral de limitación de contraste. En el proceso de sintonización de la técnica de filtrado CLAHE se obtuvo un mejor desempeño al implementar la configuración de casilla aun tamaño de 8x8 con un umbral de 3.0, teniendo como resultado un 89.64% de exactitud; además, se presentó una reducción en los tiempos de entrenamiento lo cual conlleva a ejecutar un menor consumo computacional.

En la séptima fase de experimentación, se ajustaron los hiperparámetros del modelo VGG-16 para mejorar su desempeño. Se experimentó con optimizadores, aumento de épocas, preprocesamiento de datos y otras técnicas. La configuración final incluyó aumento de datos (acercamiento, rotación y desplazamiento), 150 épocas, tamaño de lote de 32, optimizador Adadelta con factor de aprendizaje 0.001, y función de pérdida de entropía cruzada binaria, entre otros ajustes. Con esta configuración, el

modelo alcanzó una exactitud del 90.09% en la clasificación COVID-19/NOCOV-19, demostrando ser más robusto y confiable.

En la última prueba, se aumentaron las imágenes del conjunto normalizado para mejorar el entrenamiento del modelo propuesto. Después de procesar las radiografías excluidas y aplicarle la técnica CLAHE, se formó un nuevo conjunto de datos con 3,019 imágenes de COVID-19 y NOCOVID-19 para entrenamiento, validación y prueba. Posteriormente, se realizó un nuevo entrenamiento utilizando los hiperparámetros ajustados, los mejores resultados de la técnica CLAHE y los pesos de la mejor época (123), obteniendo de esta manera un modelo eficiente que presentó una exactitud del 92.34% en la clasificación COVID-19/NOCOV-19 en 4 horas y 35 minutos.

## Capítulo 6

### Conclusiones y Trabajo Futuro

En este capítulo, se realiza un análisis de las conclusiones logradas, objetivos y alcances con respecto a las actividades elaboradas durante el desarrollo de la tesis.

#### 6.1 Conclusiones

##### 6.1.1 Objetivos y Alcances Logrados

En la Tabla 6.1, se muestran las actividades realizadas con relación a los objetivos y en la Tabla 6.2, se puede observar los alcances planteados para el desarrollo de este trabajo de investigación de tesis.

**Tabla 6. 1.** Objetivos realizados.

Objetivo	Actividad
Comprender los conceptos básicos de las imágenes de radiografía de tórax.	Se estudió los conceptos básicos de imágenes de radiografías de tórax y las anomalías presentes para determinar el prediagnóstico de COVID-19.
Estudiar las Redes Neuronales Convolucionales y sus aplicaciones en la clasificación de imágenes médicas.	Se estudiaron documentos presentados en el estado del arte y marco conceptual; que describen las partes y procesos de un modelo de red neuronal convolucional y se analizaron trabajos de investigación previos que implementaron diferentes modelos de redes neuronales convolucionales en el proceso de clasificación de imágenes de radiografía de tórax de la patología de COVID-19.
Seleccionar un modelo de Red Neuronal Convolucional para la clasificación de imágenes.	Se seleccionó el modelo de RNC VGG-16 debido a su desempeño mostrado en el proceso de experimentación, al clasificar eficientemente las imágenes de Radiografía de Tórax de COVID-19 y otras enfermedades (presentado en el capítulo 5).
Recopilar y seleccionar radiografías de tórax de pacientes diagnosticados, con COVID-19 y patologías que presenten hallazgos similares a COVID-19 en etapas tempranas de la enfermedad.	Se realizó la compilación de 11 diferentes conjuntos de imágenes de radiografías de tórax de pacientes considerando dos clases: COVID-19 y NO COVID-19. Se realizó el cribado de las imágenes recopiladas, obteniendo un total de 6,050 imágenes de la clase COVID-19 y 10,969 NO COVID-19. Después, se implementó la técnica de normalización a las radiografías de tórax. Como resultado se obtuvo un nuevo conjunto de imágenes de radiografías normalizadas denominado COVID-TECNM.

**Tabla 6.1.** Objetivos realizados (Continuación).

Objetivo	Actividad
Evaluar técnicas de preprocesamiento de imágenes médicas para realzar características relevantes y la mejora de su calidad visual.	Se revisaron de trabajos previos que implementaron técnicas de preprocesamiento de filtrado para radiografías. Se seleccionaron las técnicas de HE, BCET, CLAHE, NCLAHE y Corrección Gamma; dichas técnicas se aplicaron al conjunto de imágenes desarrollado RNC COVID-TECNM para valorar visualmente las imágenes obtenidas y no presentar subexposición y sobreexposición.
Implementar un sistema basado en un modelo de Red Neuronal Convolutacional, haciendo uso de diferentes técnicas de preprocesamiento y clasificación de radiografías de tórax.	Se realizaron múltiples experimentaciones para la comparación cuantitativa de los resultados obtenidos al ejecutar pruebas con el modelo de RNC VGG-16 implementando técnicas de preprocesamiento para el aumento del conjunto de datos del conjunto de entrenamiento y las técnicas de filtrado HE, BCET, CLAHE, NCLAHE y Corrección Gamma.
Realizar experimentación y evaluación del desempeño del sistema propuesto con el conjunto de imágenes recopiladas previamente etiquetadas.	Se realizaron exhaustivas pruebas para la experimentación y evaluación del desempeño del modelo VGG-16 implementando la técnica de filtrado CLAHE; obteniendo la sintonización del modelo haciendo uso del conjunto de datos COVID-TECNM. Después se evaluó con un nuevo conjunto de datos, pero aumentado en la cantidad de imágenes normalizadas.

**Tabla 6. 2.** Alcances realizados.

Alcances	Actividad
Analizar modelos de Redes Neuronales Convolucionales.	Se analizaron varios modelos de RNC mediante la revisión ardua de los trabajos previos del estado del arte presente en el capítulo 3.
Analizar el proceso de clasificación en las Redes Neuronales Convolucionales.	Mediante el estudio de las partes y procesos de una Red Neuronal Convolutacional realizada durante la revisión del estado del arte y marco teórico.
Emplear imágenes de radiografías de tórax en escala de grises.	Se implementaron imágenes de radiografía de tórax en dos tipos de dimensionalidad en 3 canales (RGB) y en un solo canal (escala de grises).

**Tabla 6.2.** Alcances realizados (Continuación).

Alcances	Actividad
Utilizar diferentes técnicas de preprocesamiento	Se implementaron técnicas de preprocesamiento para el proceso de normalización y aumento de los datos; además, se implementaron técnicas de filtrado utilizadas en imágenes de Radiografía de Tórax.
Implementar una metodología basada en una arquitectura de Red Neuronal Convolutiva para la clasificación de imágenes de radiografía de tórax en las clases COVID-19 y otras enfermedades respiratorias.	Se ejecutaron múltiples experimentaciones de modelos de redes neuronales convoluciones para observar sus desempeños en la clasificación de la enfermedad COVID.19. Se puede observar la serie de experimentaciones en el capítulo 5 del este trabajo de investigación.
Evaluar el desempeño de la metodología propuesta con parte del conjunto de imágenes recolectadas previamente etiquetadas.	Se evaluó el modelo de Red Neuronal Convolutiva VGG-16 implementando la configuración de los hiperparámetros de la arquitectura sintonizada, la configuración con mejor eficacia de la técnica de Filtrado CLAHE y utilizando los pesos de la época con mejor desempeño siendo esta la 123 determinada por el análisis de las épocas del entrenamiento. Obteniendo una Exactitud del 92.34% al clasificar COVID-19 y NOCOVID-19.

## 6.1.2 Resultados del Trabajo

### Productos

Durante el desarrollo de este trabajo de investigación se obtuvieron los siguientes productos:

1. Reporte del estado del arte: durante el segundo periodo se realizó un documento en el que se presenta de manera resumida un conjunto de publicaciones recientes sobre trabajo relacionados al trabajo de investigación.
2. Conjunto de Imágenes: durante el desarrollo de este trabajo de investigación se realizó la compilación de 11 diferentes conjuntos de imágenes de radiografías de tórax se consideraron cuatro clases COVID-19, Neumonía Viral, Neumonía Bacteria y NOCOVID-19; consecuente se realizó un proceso de cribado donde se conformó un conjunto con COVID-19: 6,050, Neumonía Viral: 2,767, Neumonía Bacteriana: 2,630 y NOCOVID-19: 10,969. Después se realizó al conjunto de imágenes el proceso de normalización, obteniendo al final un conjunto titulado como COVID-TECNM el cual tiene registro ante el INDAUTOR, es conformado por COVID-19: 3,336, Neumonía Bacteriana: 1,369, Neumonía Viral:1,376 y NOCOVID: 3,361. Se puede observar el registro ante INDAUTOR en la Figura A.1.

3. Modelo de Red Neuronal Convolutacional para la clasificación de COVID-19 y NO COVID-19. En el capítulo 4, se describe la metodología desarrollada durante este trabajo de investigación.
4. Software desarrollado para la implementación métodos de preprocesamiento aplicando las técnicas de filtrado HE, BCET, CLAHE, NCLAHE y Corrección Gamma.
5. Artículo “Análisis de Técnicas de Preprocesamiento para la Clasificación de Radiografías Torácicas de Pacientes con COVID-19 y otras Afectaciones Pulmonares Implementando Redes Neuronales Convolucionales”

Se realizó un artículo, que fue publicado en el Congreso Internacional de Investigación “Academia Journals Celaya 2022”. Libro Digital: “Academia Journals” Año de 2022: ISSN online 1946-5351 Vol. 14, No. 9, 2022. Se puede observar la portada en la Figura A.2.

6. Se impartieron 2 talleres:
  - 1er Taller: Inteligencia Artificial en el Tecnológico de Monterrey: Campus Xochitepec (se puede observar el reconocimiento en la Figura A.3).
  - 2do Taller: *Deep Learning*: Clasificación y Delimitación durante el 12° Congreso Internacional de Computación 2022 (se puede observar la constancia en la Figura A.4).
7. Participación como miembro del Comité Evaluador del 12° Congreso Internacional de Computación 2022 (se puede observar la constancia en la Figura A.5).

## **Aportaciones**

1. Desarrollo de un modelo de Red Neuronal Convolutacional para la clasificación de imágenes de radiografía de tórax en las clases COVID-19 y NOCOVID-19. Implementando como base el modelo VGG-16.
2. Diseño del preprocesamiento de imágenes de radiografía de tórax para efectuar una mayor discriminación en el proceso de clasificación. Se implementaron las técnicas de filtrado: Ecuilización del Histograma, la Técnica de Mejora de Contraste Equilibrado, la Ecuilización Adaptativa del Histograma Limitada por el Contraste, la Corrección Gamma y NCLAHE.

3. Creación del nuevo conjunto de imágenes normalizadas de enfermedades respiratorias: 1,376 de Neumonía Viral, 1,369 de Neumonía Bacteriana, 3,336 de COVID-19 y 3,361 de NOCOVID-19, registrado ante el INDAUTOR (Figura A.1) con el nombre COVID-TECNM (Reyes, et al., 2022); el proceso de normalización consiste en descartar imágenes que presenten algunas de las características mencionadas anteriormente, que no se pudieran recortar estas regiones de la imagen sin dañar la zona pulmonar de la imagen en el la presencia de diferentes tipos de dispositivos médicos u objetos personales del paciente modificando aquellas imágenes que se pudieron extraer estos objetos o etiquetas, sin dañar el área pulmonar del tórax.
4. Desarrollo del modelo de Red Neuronal Convolutiva capaz de obtener una exactitud del 92.34%, una precisión del 92.37%, una Sensibilidad del 92.34% y Valor-F1 del 92.34%. Implementando como hiperparámetros el optimizador *Adadelta* con un factor de aprendizaje del 0.001, tamaño de lotes de 32 imágenes, técnica del abandono del 30%. Con un entrenamiento 123 épocas con imágenes RGB en formato de compresión PNG con dimensionalidad de las imágenes del  $224 \times 224 \times 3$  y función de clasificación *softmax*.

## Conclusiones

Al culminar este trabajo de investigación, se concluye que:

El implementar modelos de Redes Neuronales Convolucionales para la clasificación de múltiples enfermedades respiratorias es una tarea difícil, debido a la similitud presente de afectaciones pulmonares en una imagen de radiografía de tórax, se manifestó una extensa cantidad de clasificaciones incorrectas, obteniendo resultados de casos de falsos positivos (error de tipo 1) y falsos negativos (error de tipo 2); debido a esto el modelo propuesto realiza una clasificación binaria entre las clases COVID-19 y NOCOVID-19.

Referente al implementar imágenes de radiografía de tórax para el entramiento de un modelo de Red Neuronal convolucional, se concluye que no es suficiente únicamente de disponer de una reducida cantidad imágenes e implementarlas de manera en crudo. Durante el análisis de estas imágenes se observó diferentes casos en los cuales la imagen presentaba carencia de calidad visual causada por la presencia de objetos en la imagen, sobreexposición y subexposición; además, de presentar ruido Impulsivo y Gaussiano. Lo anterior generó que fuera de gran importancia el implementar técnicas de preprocesamiento de imágenes; lo cual permitió realizar el cribado de las imágenes recopiladas y la mejora visual del conjunto de datos, de esta forma eficientizar el proceso de extracción de características realizado por el modelo propuesto en el proceso de clasificación.

En los modelos de Redes Neuronales Convolucionales, se debe implementar el ajuste de parámetros (optimizador, épocas de entrenamiento, tamaño de lote, tasa de aprendizaje) para la mejora en el proceso de entrenamiento debido a que permiten mejorar la eficiencia de la exactitud en el proceso de discriminación realizado por el clasificador.

Al considerar lo antes mencionado, en este trabajo se establecieron los módulos de adquisición y selección de conjuntos de imágenes médicas, análisis y selección de técnicas de preprocesamiento, desarrollo del repositorio de radiografías de tórax y, análisis y selección de técnicas de clasificación. Se concluye que la implementación de Redes Neuronales Convolucionales en la clasificación de imágenes de radiografía de tórax en las clases COVID-19 y NOCOVID-19 demostró un rendimiento de exactitud del 92.34%, una precisión del 92.37%, una Sensibilidad del 92.34% y Valor-F1 del 92.34%. Durante la pandemia de COVID-19, el diagnóstico de la enfermedad era deficiente, debido a la reducida accesibilidad de pruebas químicas o de personal médico capacitado; por lo que resulta ser factible el implementar el modelo de aprendizaje profundo de Redes neuronales Convolucionales para el prediagnóstico de la

enfermedad. Implementando un Aumento de datos del conjunto de entrenamiento: acercamiento de 20% de acercamiento a la imagen, Rotación de un ángulo de rotación del 20% y desplazamiento del 10% de desplazamiento a lo alto y largo de la imagen, una dimensionalidad de las imágenes del  $224 \times 224 \times 3$ , 150 épocas de entrenamiento, tamaño del lote de 32 imágenes, con un abandono del 30%, utilizando el optimizador Adadelta con un factor de aprendizaje 0.001, función de pérdida de Entropía cruzada binaria, función de clasificación softmax, transferencia de aprendizaje con el conjunto ImageNet y los pesos implementados de la época 137.

## 6.2 Trabajos Futuros

El trabajo futuro de esta investigación se puede orientar en el área médica a la detección de afectaciones pulmonares implementando imágenes de radiografía de tórax y modelos de Redes Neuronales Convolucionales para la detección de objetos, para la identificación y localización de las afectaciones pulmonares de manera independiente en una imagen de radiografía; permitiendo que un especialista medico pueda realizar de manera más eficiente y rápida el diagnostico de enfermedades respiratorias.

De acuerdo a los resultados obtenidos en este trabajo de tesis, se plantea como iniciativa realizar pruebas del rendimiento de la Red Neuronal convolucional propuesta, modificando su arquitectura, proponiendo el aumentado el número de capas de Convolución, modificar la capa de entrada para poder implementar imágenes con mayores dimensiones, integrar mayor cantidad de capas de muestreo max pooling, implementar otros tipos de técnicas de filtrado y realizar la experimentación de otros tipos de clasificadores como por ejemplo SVM.

## Referencias

- Abdar, A., Sadjadi, S., Soltanian-Zadeh, H., Bashirgonbadi, A., & Naghibi, M. (2020). Automatic detection of Coronavirus (COVID-19) from chest CT images using VGG16-based deep-learning. 2020 27th National and 5th International Iranian Conference on Biomedical Engineering (ICBME).
- Agchung. (2020, 8 mayo). Figure 1 COVID-19 Chest X-ray Dataset Initiative. GitHub. <https://github.com/agchung/Figure1-COVID-chestxray-dataset>
- Ahamed, K., Islam, M., Uddin, A., Akhter, A., Paul, B., Yousuf, M., Uddin, S., Quinn, J., & Moni, M. (2021). A deep learning approach using effective preprocessing techniques to detect COVID-19 from chest CT-scan and X-ray images. *Computers in Biology and Medicine*, 139, 105014. <https://doi.org/10.1016/j.compbimed.2021.105014>
- Akter, S., Shamrat, F. M. J. M., Chakraborty, S., Karim, A., & Azam, S. (2021). COVID-19 Detection Using Deep Learning Algorithm on Chest X-ray Images. *Biology*, 10(11), 1174. <https://doi.org/10.3390/biology10111174>
- Beitzel, S. M. (2006). ON Understanding And Classifying Web Queries, Chicago, Illinois. (Ph.D. thesis).
- Bhattacharya, S., Reddy Maddikunta, P. K., Pham, Q.-V., Gadekallu, T. R., Krishnan S, S. R., Chowdhary, C. L., Alazab, M., & Jalil Piran, M. (2021). Deep learning and medical image processing for coronavirus (COVID-19) pandemic: A survey. *Sustainable Cities and Society*, 65(102589), 102589. <https://doi.org/10.1016/j.scs.2020.102589>
- Brownlee, J. P. (diciembre de 2017). A Gentle Introduction to Transfer Learning for Deep Learning. Obtenido de <https://machinelearningmastery.com/transfer-learning-for-deep-learning/>
- BSTI, A. (2020). BSTI Covid19 Teaching Library. Cimar. [https://bsticovid19.cimar.co.uk/route?route=view\\_study\\_list\\_with\\_sid&sid=7962ba0d-7134-451c-864e-2646bd40b2b2](https://bsticovid19.cimar.co.uk/route?route=view_study_list_with_sid&sid=7962ba0d-7134-451c-864e-2646bd40b2b2)
- Burgal, J. (2018, diciembre 5). Deep Learning básico con Keras (Parte 4): ResNet. En *Mi Local Funciona*. <https://enmilocalfunciona.io/deep-learning-basico-con-keras-parte-4-resnet/>
- CDC. (2020). Coronaviruses.. <https://phil.cdc.gov/Details.aspx?pid=23311>
- Chest Imaging. (2020). Chest Imaging (@ChestImaging) Twitter. <https://twitter.com/ChestImaging>.
- Chollet, F. (2017). Deep learning with python. Manning Publications.

- Chollet, F. (2017). Xception: Deep Learning with Depthwise Separable Convolutions. Xception: Deep Learning with Depthwise Separable Convolutions, 1. <https://arxiv.org/abs/1610.02357v3>.
- Chowdhury, M. E. H., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M. A., Mahbub, Z. B., Islam, K. R., Khan, M. S., Iqbal, A., Emadi, N. A., Reaz, M. B. I., & Islam, M. T. (2020). Can AI Help in Screening Viral and COVID-19 Pneumonia? *IEEE Access*, 8, 132665–132676. <https://doi.org/10.1109/access.2020.3010287>.
- Dadario A. (2020). COVID-19 X rays. <https://doi.org/10.34740/KAGGLE/DSV/1019469>.
- Das, A., Kalam, S., Kumar, C., & Sinha, D. (2021). TLCoV- An automated Covid-19 screening model using Transfer Learning from chest X-ray images. *Chaos, Solitons, and Fractals*, 144(110713), 110713. <https://doi.org/10.1016/j.chaos.2021.110713>
- Desai, S., Baghal, A., Wongsurawat, T., Al-Shukri, S., Gates, K., Farmer, P., Rutherford, M., Blake, G.D., Nolan, T., Powell, T., Sexton, K., Bennett, W., Prior, F. (2020). Data from Chest Imaging with Clinical and Genomic Correlates Representing a Rural COVID-19 Positive Population [Data set]. The Cancer Imaging Archive. DOI: <https://doi.org/10.7937/tcia.2020.py71-5978>.
- Dey, S. (2018). Hands-on image processing with Python. Packt Publishing.
- Díaz, I. (2014). Imágenes diagnósticas: Conceptos y generalidades. *Revista de la Facultad de Ciencias Médicas*, 35-42.
- Dipanjan (DJ), S. (2018). A Comprehensive Hands-on Guide to Transfer Learning with Real World Applications in Deep Learning. Obtenido de <https://towardsdatascience.com/acomprensive-hands-on-guide-to-transfer-learning-with-real-world-applications-indeep-learning-212bf3b2f27a>
- Dutta, M. K. (2021), COVID Chest X-Rays, Mendeley Data, V1, doi: 10.17632/4n66brtp4j.1.
- Gan, W. S. (2020). Signal Processing and Image Processing for Acoustical Imaging. Springer Publishing.
- Gestoso-Pecellín, L., García-Flores, Y., González-Quintana, P., & Marrero-Arencibia, J. L. “Recomendaciones y uso de los diferentes tipos de test para detección de infección por SARS-COV-2”. *Enfermería clínica*, Vol. 31, No. S40–S48, 2021. <https://doi.org/10.1016/j.enfcli.2020.10.001>.
- González, A. (2018). Aplicaciones de técnicas de inteligencia artificial basadas en aprendizaje profundo (deep learning) al análisis y mejora de la eficiencia de procesos industriales. Universidad de Oviedo.

- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. Amsterdam University Press.
- Gugger, S., & Howard, J. (2020). *Deep learning for coders with fastai and PyTorch: AI applications without a PhD*. O'Reilly Media.
- Gupta, A., Anjum, S., & Katarya, R. (2021). InstaCovNet-19: A deep learning classification model for the detection of COVID-19 patients using Chest X-ray. *Applied Soft Computing*, 99(106859), 106859. <https://doi.org/10.1016/j.asoc.2020.106859>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
- Heidari, M., Mirniaharikandehei, S., Khuzani, A. Z., Danala, G., Qiu, Y., & Zheng, B. (2020). Improving the performance of CNN to predict the likelihood of COVID-19 using chest X-ray images with preprocessing algorithms. *International Journal of Medical Informatics*, 144, 104284. <https://doi.org/10.1016/j.ijmedinf.2020.104284>
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. En *arXiv [cs.CV]*. <https://doi.org/10.48550/ARXIV.1704.04861>
- Hu, Z., Yang, Z., Lafata, K. J., Yin, F. F., & Wang, C. (2021). A Radiomics-Boosted Deep-Learning Model for COVID-19 and Non-COVID-19 Pneumonia Classification Using Chest X-ray Image. *arXiv preprint arXiv:2107.08667*
- Ibrahim, D., Elshennawy, N., & Sarhan, A. (2021). Deep-chest: Multi-classification deep learning model for diagnosing COVID-19, pneumonia, and lung cancer chest diseases. *Computers in Biology and Medicine*, 132(104348), 104348. <https://doi.org/10.1016/j.combiomed.2021.104348>
- Jain, G., Mittal, D., Thakur, D., & Mittal, M. K. (2020). A deep learning approach to detect Covid-19 coronavirus with X-Ray images. *Biocybernetics and Biomedical Engineering*, 40(4), 1391–1405. <https://doi.org/10.1016/j.bbe.2020.08.008>.
- Jones, J., & Murphy, A. (2018). Radiographic contrast (en línea), consultada por Internet el 15 de abril del 2022. Dirección de internet: [http:// radiopaedia.org](http://radiopaedia.org).
- Kanne, J. P., Little, B. P., Chung, J. H., Elicker, B. M., & Ketai, L. H. (2020). Essentials for radiologists on COVID-19: An update-radiology scientific expert panel. *Radiology*, 296(2), E113–E114. <https://doi.org/10.1148/radiol.2020200527>
- Keidar, D., Yaron, D., Goldstein, E., Shachar, Y., Blass, A., Charbinsky, L., Aharony, I., Lifshitz, L., Lumelsky, D., Neeman, Z., Mizrachi, M., Hajouj, M., Eizenbach, N., Sela, E., Weiss, C. S., Levin, P., Benjaminov, O., Bachar, G. N., Tamir, S., Eldar, Y. C. (2021). COVID-19 classification of X-ray images using deep neural networks. *European Radiology*, 31(12), 9654–9663. <https://doi.org/10.1007/s00330-021-08050-1>

- Khan, S., Rahmani, H., Shah, S., & Bennamoun, M. (2018). A Guide to Convolutional Neural Networks for Computer Vision. *Synthesis lectures on computer vision*, 8(1), 1–207. <https://doi.org/10.2200/s00822ed1v01y201712cov015>
- Khasawneh, N., Fraiwan, M., Fraiwan, L., Khassawneh, B., Ibnian, A. (2021), COVID-19 Chest X-ray Images, Mendeley Data, V2, doi: 10.17632/xzwtjwmktrg.2.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. <https://doi.org/10.1145/3065386>
- Lalmuanawma, S., Hussain, J., & Chhakchhuak, L. (2020). Applications of machine learning and artificial intelligence for Covid-19 (SARS-CoV-2) pandemic: A review. *Chaos, Solitons, and Fractals*, 139(110059), 110059. <https://doi.org/10.1016/j.chaos.2020.110059>
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Maguiña Vargas, C., Gastelo Acosta, R., & Tequen Bernilla, A. (2020). El nuevo Coronavirus y la pandemia del Covid-19. *Revista médica herediana : órgano oficial de la Facultad de Medicina “Alberto Hurtado”, Universidad Peruana Cayetano Heredia, Lima, Perú*, 31(2), 125–131. <https://doi.org/10.20453/rmh.v31i2.3776>
- Manna, S., Wruble, J., Maron, S. Z., Toussie, D., Voutsinas, N., Finkelstein, M., Cedillo, M. A., Diamond, J., Eber, C., Jacobi, A., Chung, M., & Bernheim, A. (2020). COVID-19: A Multimodality Review of Radiologic Techniques, Clinical Utility, and Imaging Features. *Radiology: Cardiothoracic Imaging*, 2(3), e200210. <https://doi.org/10.1148/ryct.2020200210>.
- Martínez, E., Díez, A., Ibáñez, L., Ossaba, S., & Borruel, S. (2021). Diagnóstico radiológico del paciente con COVID-19. *Radiología (English Edition)*, 63(1), 56–73. <https://doi.org/10.1016/j.rx.2020.11.001>
- Matuz, M. (2017). Detección de anormalidades en mamografías utilizando la red neuronal convolucional alexnet. Master’s thesis, Centro Nacional de Investigación y Desarrollo Tecnológico CENIDET.
- Mostafiz, R., Uddin, M., Alam, N., Mahfuz, M., & Rahman, M. (2020). Covid-19 detection in chest X-ray through random forest classifier using a hybridization of deep CNN and DWT optimized features. *Journal of King Saud University - Computer and Information Sciences*. <https://doi.org/10.1016/j.jksuci.2020.12.010>
- Murphy, A. Optimal exposure in digital radiography, 2019 (en línea), consultada por Internet el 21 de abril del 2022. Dirección de internet: [http:// radiopaedia.org](http://radiopaedia.org).

- OMS. (2020). Transmisión del SARS-CoV-2: repercusiones sobre las precauciones en materia de prevención de infecciones. [https://apps.who.int/iris/bitstream/handle/10665/333390/WHO-2019nCoV-Sci\\_Brief-Transmission\\_modes-2020.3-spa.pdf](https://apps.who.int/iris/bitstream/handle/10665/333390/WHO-2019nCoV-Sci_Brief-Transmission_modes-2020.3-spa.pdf).
- Ozturk, T., Talo, M., Yildirim, E. A., Baloglu, U. B., Yildirim, O., y Rajendra Acharya, U. "Automated detection of COVID-19 cases using deep neural networks with X-ray images". *Computers in Biology and Medicine*, Vol. 121, No. 103792, 2020. <https://doi.org/10.1016/j.combiomed.2020.103792>.
- Peng, P., & Wang, J. (2020). How to fine-tune deep neural networks in few shot learning? arXiv [cs.LG]. <https://doi.org/10.48550/ARXIV.2012.00204>
- Pereira, S., Pinto, A., Alves, V., & Silva, C. A. (2016). Brain tumor segmentation using Convolutional Neural Networks in MRI images. *IEEE Transactions on Medical Imaging*, Vol. 35, No. 5. <https://doi.org/10.1109/TMI.2016.2538465>
- Pérez, E. (2020). Nuevo coronavirus 2019-ncov: impacto en salud global. *Ciencia y Salud*, 4(1), 5–9. <https://doi.org/10.22206/cysa.2020.v4i1.pp5-9>
- Pezzotti, W. (2014). Interpretación de la radiografía de tórax: algo más que blanco y negro. *Nursing*, 31(5), 30–37. <https://doi.org/10.1016/j.nursi.2014.10.012>
- Rahimzadeh, M., & Attar, A. (2020). A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2. *Informatics in Medicine Unlocked*, 19(100360), 100360. <https://doi.org/10.1016/j.imu.2020.100360>
- Rahman, T., Khandakar, A., Qiblawey, Y., Tahir, A., Kiranyaz, S., Abul Kashem, S., Islam, M., Al Maadeed, S., Zughaier, S., Khan, M., & Chowdhury, M. (2021). Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images. *Computers in Biology and Medicine*, 132, 104319. <https://doi.org/10.1016/j.combiomed.2021.104319>
- Raptis, C., Hammer, M., Short, R., Shah, A., Bhalla, S., Bierhals, A., Filev, P., Hope, M., Jeudy, J., Kligerman, S., & Henry, T. (2020). Chest CT and Coronavirus Disease (COVID-19): A Critical Review of the Literature to Date. *American Journal of Roentgenology*, Vol. 215 No. 4, 839–842. <https://doi.org/10.2214/ajr.20.23202>
- Redes neuronales convolucionales. (Mathworks). Mathworks.com. Recuperado el 16 de Julio de 2021, de <https://la.mathworks.com/discovery/convolutional-neural-network-matlab.html>
- Reyes, E., González, N., Mújica, D., López, M., Salazar, A., & Pinto, R. COVID-TECNM [Data set], 2022.

- Seibert, J., & Morin, R. (2011) The standardized exposure index for digital radiography: an opportunity for optimization of radiation dose to the pediatric population. *Pediatric Radiology*, Vol. 41, No. 5. <https://doi.org/10.1007/s00247-010-1954-6>.
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0197-0>
- Singh, R. K., Pandey, R., & Babu, R. N. (2021). COVIDScreen: explainable deep learning framework for differential diagnosis of COVID-19 using chest X-rays. *Neural Computing and Applications*. <https://doi.org/10.1007/s00521-020-05636-6>.
- Sundararajan, D. "Digital image processing: A signal processing and algorithmic approach". Springer, 2017.
- Suvorov, R., Logacheva, E., Mashikhin, A., Remizova, A., Ashukha, A., Silvestrov, A., Kong, N., Goka, H., Park, K., & Lempitsky, V. (2021). Resolution-robust large mask inpainting with Fourier convolutions. <https://doi.org/10.48550/ARXIV.2109.07161>
- Tajbakhsh, N., Shin, J. Y., Gurudu, S. R., Hurst, R. T., Kendall, C. B., Gotway, M. B., & Jianming Liang. (2016). "Convolutional neural networks for medical image analysis: Full training or fine tuning?". *IEEE Transactions on Medical Imaging*, Vol. 35 No. 5, 2016.
- Tsai, E., Simpson, S., Lungren, M.P., Hershman, M., Roshkovan, L., Colak, E., Erickson, B.J., Shih, G., Stein, A., Kalpathy-Cramer, J., Shen, J., Hafez, M.A.F., John, S., Rajiah, P., Pogatchnik, B.P., Mongan, J.T., Altinmakas, E., Ranschaert, E., Kitamura, F.C., Topff, L., Moy, L., Kanne, J.P., & Wu, C. (2021). Data from Medical Imaging Data Resource Center (MIDRC) - RSNA International COVID Radiology Database (RICORD) Release 1c - Chest x-ray, Covid+ (MIDRC-RICORD-1c). The Cancer Imaging Archive. DOI: <https://doi.org/10.7937/91ah-v663>.
- Turkoglu, M. (2020). COVIDetectioNet: COVID-19 diagnosis system based on X-ray images using features selected from pre-learned deep features ensemble. *Applied Intelligence*, 51(3), 1–14. <https://doi.org/10.1007/s10489-020-01888-w>
- Ucar, F., & Korkmaz, D. (2020). COVIDiagnosis-Net: Deep Bayes-SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-ray images. *Medical Hypotheses*, 140(109761), 109761. <https://doi.org/10.1016/j.mehy.2020.109761>
- Westphal, E., & Seitz, H. (2021). A machine learning method for defect detection and visualization in selective laser sintering based on convolutional neural networks. *Additive Manufacturing*, 41(101965), 101965. <https://doi.org/10.1016/j.addma.2021.101965>

- Westra, D., & Sperber, M. (2001). Conventional chest radiography". *Radiologic Diagnosis of Chest Disease*. Springer.
- Wolpert, D. H. (1992). Stacked generalization. *Neural networks*, 5(2), 241-259.
- Wong, H. Y. F., Lam, H. Y. S., Fong, A. H. T., Leung, S. T., Chin, T. W. Y., Lo, C. S. Y., Lui, M. M. S., Lee, J. C. Y., Chiu, K. W. H., Chung, T. W. H., Lee, E. Y. P., Wan, E. Y. F., Hung, I. F. N., Lam, T. P. W., Kuo, M. D., & Ng, M. Y. (2020). Frequency and Distribution of Chest Radiographic Findings in Patients Positive for COVID-19. *Radiology*, Vol. 296, No. 2. <https://doi.org/10.1148/radiol.2020201160>.
- Yang, X. (2019). *Introduction to Algorithms for Data Mining and Machine Learning*. Elsevier Gezondheidszorg.

## Anexo A

# CERTIFICADO

## Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 78, 162, 163 fracción II, 164 fracción I, y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **COLECCIÓN DE OBRAS DERIVADAS** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con lo siguientes datos:

<b>AUTORES DE COMPILACION:</b>	GONZALEZ FRANCO NIMROD LOPEZ SANCHEZ MAXIMO MAGADAN SALAZAR ANDREA MEDRANO MARTINEZ BRANDON JAVIER MUJICA VARGAS DANTE PINTO ELIAS RAUL REYES SANCHEZ EMANUEL
<b>TÍTULO:</b>	COVID-TECNM
<b>RAMA:</b>	COMPILACION DE DATOS (BASE DE DATOS)
<b>TITULARES DE COMPILACION:</b>	GONZALEZ FRANCO NIMROD LOPEZ SANCHEZ MAXIMO MAGADAN SALAZAR ANDREA MEDRANO MARTINEZ BRANDON JAVIER MUJICA VARGAS DANTE PINTO ELIAS RAUL REYES SANCHEZ EMANUEL

Con fundamento en el artículo 3° de la Ley Federal del Derecho de Autor el presente certificado ampara única y exclusivamente la obra original Base de Datos.

Con fundamento en lo establecido por el artículo 14 fracciones I y IV de la Ley Federal del Derecho de Autor, no es objeto de protección como derecho de autor: las ideas en sí mismas, las fórmulas, soluciones, conceptos, métodos, sistemas, principios, descubrimientos, procesos e invenciones de cualquier tipo; las letras, los dígitos o los colores aislados, a menos que su estilización sea tal que las conviertan en dibujos originales.

Con fundamento en lo establecido por el artículo 163 fracción II segundo párrafo de la Ley Federal del Derecho de Autor, esta inscripción no faculta para publicar o usar en forma alguna la obra registrada, a menos de que se acredite la autorización correspondiente.

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

1/2


CULTURA | 
 
INDAUTOR  
SECRETARÍA DE CULTURA | INSTITUTO NACIONAL DEL DERECHO DE AUTOR

Figura A. 1. Certificado de registro del conjunto COVID-TECNM.

## Análisis de Técnicas de Preprocesamiento para la Clasificación de Radiografías Torácicas de Pacientes con COVID-19 y otras Afectaciones Pulmonares Implementando Redes Neuronales Convolucionales

Ing. Emanuel Reyes Sánchez<sup>1</sup>, Dr. Nimrod González Franco<sup>2</sup>, Dr. Dante Mújica Vargas<sup>3</sup>, Dr. Máximo López Sánchez<sup>4</sup>, Dra. Andrea Magadán Salazar<sup>5</sup> y Dr. Raúl Pinto Elías<sup>6</sup>

**Resumen**—Existen Redes Neuronales Convolucionales (RNC's) aptas para clasificar radiografías de tórax de pacientes con COVID-19 u otras enfermedades respiratorias. Desafortunadamente, muchas radiografías presentan problemas de sobreexposición o subexposición, lo cual produce un contraste inadecuado que dificulta el proceso de clasificación. Este artículo presenta la implementación de Técnicas de Normalización y Filtrado para mejorar las radiografías de tórax usadas para entrenar, validar y probar las RNC's VGG-16, VGG-19, Xception, MobileNetV1, MobileNetV2 y ResNet50 adaptadas para un problema de clasificación binaria (considerando las clases COVID-19 y NO COVID-19). Los filtros implementados fueron Ecuilización del Histograma, BCET, CLAHE, N-CLAHE y Corrección Gamma. Observamos una mejora en los resultados de todas las RNC's al usar radiografías mejoradas en lugar de las radiografías en crudo, llegando a obtener hasta un incremento del 14.91% en Accuracy, 5.5% en Precision, 14.91% en Recall y 18.06 F1-Score para la VGG-16 tras aplicar Normalización y el filtro CLAHE.

**Palabras clave**— COVID-19, Redes Neuronales Convolucionales, Radiografía de Tórax, Aprendizaje Profundo, y Preprocesamiento.

### Introducción

En las radiografías de tórax de pacientes con COVID-19 se llegan a percibir anomalías en las regiones pulmonares, generalmente llamadas hallazgos, caracterizados por opacidades recíprocas multifocales, similares a vidrio esmerilado, con una diseminación marginal en la etapa temprana y tardía de la infección; por este motivo, se considera el análisis de radiografías de tórax como un método para el diagnóstico de dicha enfermedad (Huang, 2021). En un esfuerzo por tener herramientas para el diagnóstico automático de COVID-19, se han realizado diversas investigaciones orientadas a desarrollar o adaptar diversos modelos de aprendizaje profundo para la clasificación de radiografías de pacientes que presenten hallazgos de COVID-19 y otras enfermedades (Ozturk, et al., 2020 y Gestoso, et al., 2021). Sin embargo, en su gran mayoría los investigadores no consideraron que, en muchos casos, las radiografías de tórax presentan problemas de sobreexposición o subexposición, lo que ocasiona un alto o bajo contraste radiográfico afectando la identificación y comprensión de los hallazgos asociados a una enfermedad (Murphy, 2019; Seibert, et al., 2011; Jones & Murphy., 2018 y Westra & Sperber, 2001). Debido a esto, se requiere implementar técnicas de preprocesamiento para mejorar la calidad visual de las radiografías de tórax, además, se sabe que la implementación de estas técnicas destaca las características presentes en la imagen.

De acuerdo a la literatura, se han implementado diferentes técnicas de preprocesamiento en imágenes médicas en conjunto con Redes Neuronales Convolucionales para la predicción de COVID-19 mediante clasificación (Rahman, et al., 2021); sin embargo, estos trabajos únicamente implementaron técnicas de filtrado con

<sup>1</sup> El Ing. Emanuel Reyes Sánchez es Estudiante de Maestría en Ciencias Computacionales en el Centro Nacional de Investigación y Desarrollo Tecnológico, Morelos, México. m21ce025@cenidet.tecnm.mx

<sup>2</sup> El Dr. Nimrod González Franco es Profesor Investigador del Departamento de Ciencias Computacionales en el Centro Nacional de Investigación y Desarrollo Tecnológico, Morelos, México. nimrod.gf@cenidet.tecnm.mx

<sup>3</sup> El Dr. Dante Mújica Vargas es Profesor Investigador del Departamento de Ciencias Computacionales en el Centro Nacional de Investigación y Desarrollo Tecnológico, Morelos, México. dante.mv@cenidet.tecnm.mx

<sup>4</sup> El Dr. Máximo López Sánchez es Profesor Investigador del Departamento de Ciencias Computacionales en el Centro Nacional de Investigación y Desarrollo Tecnológico, Morelos, México. maximo.ls@cenidet.tecnm.mx

<sup>5</sup> La Dra. Andrea Magadán Salazar es Profesora Investigadora del Departamento de Ciencias Computacionales en el Centro Nacional de Investigación y Desarrollo Tecnológico, Morelos, México. andrea.ms@cenidet.tecnm.mx

<sup>6</sup> El Dr. Raúl Pinto Elías es Profesor Investigador del Departamento de Ciencias Computacionales en el Centro Nacional de Investigación y Desarrollo Tecnológico, Morelos, México. raul.pe@cenidet.tecnm.mx

**Figura A. 2.** Artículo de Congreso publicado en Academia Journals Celaya 2022.



**Figura A. 3.** Reconocimiento por el Taller: Inteligencia Artificial en el Tecnológico de Monterrey: Campus Xochitepec.



**Figura A. 4.** Constancia por el Taller: Deep Learning: Clasificación y Delimitación durante el 12° Congreso Internacional de Computación 2022.



**Figura A. 5.** Constancia por participación como miembro del Comité Evaluador del 12° Congreso Internacional de Computación 2022.