

**UNIVERSIDAD NACIONAL DEL SANTA**  
**ESCUELA DE POSGRADO**  
**Programa de Doctorado en Estadística Matemática**



**UNS**  
ESCUELA DE  
**POSGRADO**

---

---

**Modelos DEEP LEARNING para diagnóstico de COVID-19  
con tomografías computarizadas de KAGGLE**

---

---

**Tesis para optar el grado de  
Doctor en Estadística Matemática**

**Autor:**

**M.Sc. Fernández Vásquez, Richard Fernando**  
**Código Orcid: 0000-0003-1721-8527**

**Asesor:**

**Dr. Rubio Jacobo, Luis Alberto**  
**Código ORCID: 0000-0001-5060-9998**  
**DNI N° 18069833**

**Línea de Investigación**  
**Métodos estadísticos en bioinformática**

**Nuevo Chimbote - PERÚ**  
**2024**



**UNS**  
ESCUELA DE  
POSGRADO

**CONSTANCIA DE ASESORAMIENTO DE LA TESIS**

Yo, DR. RUBIO JACOBO, LUIS ALBERTO, mediante la presente certifico mi asesoramiento de la Tesis de doctorado titulada: **MODELOS DEEP LEARNING PARA DIAGNÓSTICO DE COVID-19 CON TOMOGRAFÍAS COMPUTARIZADAS DE KAGGLE**, elaborado por el doctorando M.S. **FERNÁNDEZ VÁSQUEZ, RICHARD FERNANDO**, para obtener el Grado Académico de Doctor en **ESTADÍSTICA MATEMÁTICA** en la Escuela de Posgrado de la Universidad Nacional del Santa.

Nuevo Chimbote, diciembre de 2024

DR. RUBIO JACOBO, LUIS ALBERTO

ASESOR

CODIGO ORCID 0000-0001-5060-9998

DNI N° 18069833



**UNS**  
ESCUELA DE  
POSGRADO

**HOJA DEL AVAL DEL JURADO EVALUADOR**

**MODELOS DEEP LEARNING PARA DIAGNÓSTICO DE COVID-19 CON  
TOMOGRAFÍAS COMPUTARIZADAS DE KAGGLE**

**TESIS PARA OPTAR EL GRADO DE DOCTOR EN ESTADÍSTICA MATEMÁTICA**

Revisado y Aprobado por el Jurado Evaluador:

**Dra. González Castro, Jeanette Baldramina**

PRESIDENTE

CODIGO ORCID 0000-0003-4661-7447

DNI N° 17907323

**Dr. Calderón Yarleque, Luis Alberto**

SECRETARIO

CODIGO ORCID 0000-0002-6870-5096

DNI N° 40097132

**Dr. Rubio Jacobo, Luis Alberto**

VOCAL

CODIGO ORCID 0000-0001-5060-9998

DNI N° 18069833



**UNS**  
ESCUELA DE  
POSGRADO

### ACTA DE EVALUACIÓN DE SUSTENTACIÓN DE TESIS

A los trece días del mes de diciembre del año 2024, siendo las 11:30 am horas, en el aula P-02 de la Escuela de Posgrado de la Universidad Nacional del Santa, se reunieron los miembros del Jurado Evaluador, designados mediante Resolución Directoral N° 590-2024-EPG-UNS de fecha 20.11.2024, conformado por los docentes: Dra. Jeanette Baldramina González Castro (Presidenta), Dr. Luis Alberto Calderón Yarleque (Secretario) y Dr. Luis Alberto Rubio Jacobo (Vocal); con la finalidad de evaluar la tesis titulada **"MODELOS DEEP LEARNING PARA DIAGNÓSTICO DE COVID-19 CON TOMOGRAFÍAS COMPUTARIZADAS DE KAGGLE"**; presentado por el tesista **Richard Fernando Fernández Vásquez**, egresado del programa de **Doctorado en Estadística Matemática**.

Sustentación autorizada mediante Resolución Directoral N° 618-2024-EPG-UNS de fecha 10 de diciembre de 2024.

La Presidenta del jurado autorizó el inicio del acto académico; producido y concluido el acto de sustentación de tesis, los miembros del jurado procedieron a la evaluación respectiva, haciendo una serie de preguntas y recomendaciones al tesista, quien dio respuestas a las interrogantes y observaciones.

El jurado después de deliberar sobre aspectos relacionados con el trabajo, contenido y sustentación del mismo y con las sugerencias pertinentes, declara la sustentación como Aprobada, asignándole la calificación de 20 (Excelente).

Siendo las 12:30 horas del mismo día se da por finalizado el acto académico, firmando la presente acta en señal de conformidad.

Dra. Jeanette Baldramina González Castro  
Presidenta

Dr. Luis Alberto Calderón Yarleque  
Secretario

Dr. Luis Alberto Rubio Jacobo  
Vocal/Asesor



## Recibo digital

Este recibo confirma que su trabajo ha sido recibido por Turnitin. A continuación podrá ver la información del recibo con respecto a su entrega.

La primera página de tus entregas se muestra abajo.

Autor de la entrega: Richard Fernando FERNANDEZ VASQUEZ  
Título del ejercicio: DOCTORADO 2024 - UNS  
Título de la entrega: Tesis v9 - Richard Fernández - VF2\_2 - Tunitin.docx  
Nombre del archivo: Tesis\_v9\_-\_Richard\_Fernández\_-\_VF2\_2\_-\_Tunitin.docx  
Tamaño del archivo: 1.76M  
Total páginas: 63  
Total de palabras: 12,495  
Total de caracteres: 68,276  
Fecha de entrega: 30-nov.-2024 03:25p. m. (UTC-0500)  
Identificador de la entrega... 2471556399

### I. INTRODUCCIÓN

La presente investigación aborda el covid-19, que, desde marzo del 2020, las estadísticas en el Perú empezaron a mostrar muertes ante un sistema de salud inadecuado y la limitación de camas UCI. Jesús Valverde, quien fue presidente de la Asociación Peruana de Medicina Intensiva (APMI) comentó que existen 1,400 camas UCI activas en todo el Perú, las cuales, en diciembre de 2020, 1,350 camas UCI se encontraban ocupadas, es decir, más del 90%.

A escala internacional se han llevado a cabo múltiples indagaciones realizando uso de modelos Deep Learning (DL) a fin que se diagnostique el covid-19 a través del uso de imágenes médicas. Bhattacharya et al. (2021), mencionaron que las técnicas de Deep Learning implementadas al procesamiento de imágenes han ganado un gran impulso en la salud. Apostolopoulos y Mpesiana (2020), utilizando una colección de datos de imágenes de rayos X (IRX) de GitHub, Cohen, Radiology Society of North America (RSNA), y la Sociedad Italiana de Radiología Médica e Intervencionista (SIRM) se asociaron y utilizaron una Red Neuronal Convolutiva (RNC) para detectar pacientes con covid-19. Nur-A-Alam et al. (2021), mencionaron que un diagnóstico preciso del covid-19 puede disminuir la tasa de muerte de los pacientes. Chaddad et al. (2020), haciendo uso de tomografías y rayos X (RX) de pacientes usaron Deep Learning y entrenaron diferentes arquitecturas de RNC. Minaee et al. (2020), aplicaron modelos de Deep Learning para detectar pacientes con covid-19 tomando en consideración sus imágenes de radiografía de tórax. Yang et al. (2021), haciendo uso de imágenes radiológicas y tomográficas para la identificación de COVID-19, emplearon modelos de Deep Learning y entrenaron diferentes arquitecturas de RNC. Asimismo, Akter et al. (2021), haciendo uso de un conjunto de datos de IRX del tórax entrenaron modelos de DL de diferentes arquitecturas de RNC.

La investigación busca determinar el modelo más adecuado de DL haciendo uso de una arquitectura de RNC para el diagnóstico de covid-19 empleando tomografías computarizadas de Kaggle. Concretamente, la investigación avala la hipótesis de que el modelo de DL más conveniente hacia el diagnóstico de covid-19 con tomografías computarizadas del tórax es el modelo de RNC

INFORME DE ORIGINALIDAD

18%

INDICE DE SIMILITUD

16%

FUENTES DE INTERNET

3%

PUBLICACIONES

8%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	<b>elcomercio.pe</b> Fuente de Internet	2%
2	<b>hdl.handle.net</b> Fuente de Internet	2%
3	<b>C. Giai. "Actualidad en el diagnóstico de la COVID-19", Investigación, Ciencia y Universidad, 2020</b> Publicación	1%
4	<b>ciencialatina.org</b> Fuente de Internet	1%
5	<b>Submitted to antonionarino</b> Trabajo del estudiante	1%
6	<b>Submitted to Universidad de Lima</b> Trabajo del estudiante	1%
7	<b>repositorio.uandina.edu.pe</b> Fuente de Internet	1%
8	<b>dspace.utpl.edu.ec</b> Fuente de Internet	<1%

## **DEDICATORIA**

A todas las personas que han perdido algún familiar en la pandemia por efectos del covid-19.

## **AGRADECIMIENTO**

A mi papá Fernando por estar siempre presente.

A mi esposa Lesly por su amor incondicional.

A mis amigos de mi promoción del colegio y en especial este año, a mi gran amigo Carlos Torres Quispe.

A mi asesor de tesis Luis Rubio por su apoyo en este trabajo.

## ÍNDICE

<b>CERTIFICACIÓN DEL ASESOR</b>	ii
<b>AVAL DEL JURADO EVALUADOR</b>	iii
<b>LISTA DE TABLAS</b>	viii
<b>LISTA DE FIGURAS</b>	ix
<b>RESUMEN</b>	xi
<b>ABSTRACT</b>	xii
<b>I. INTRODUCCIÓN</b>	1
1.1 Descripción del problema	2
1.2 Formulación del problema	5
1.3 Objetivos	5
1.3.1 Objetivo General	5
1.3.2 Objetivos específicos	6
1.4 Formulación de la hipótesis	6
1.5 Justificación e importancia	6
<b>II. MARCO TEÓRICO</b>	8
2.1 Antecedentes	8
2.2 Marco conceptual	9
2.2.1 Covid-19	9
2.2.2 Prueba para el diagnóstico de covid-19	10
2.2.3 Tipos de prueba para el diagnóstico de covid-19	10
2.2.4 Tomografía computarizada del tórax	11
2.2.5 Inteligencia Artificial	11
2.2.6 Machine Learning	13
2.2.7 Deep Learning	14
2.2.8 Redes Neuronales Convolucionales	17
2.2.9 Arquitectura de Red Neuronal Convolutiva GoogLeNet	23
2.2.10 Arquitectura de Red Neuronal Convolutiva AlexNet	24
2.2.11 Matriz de confusión	25
2.2.12 Curva ROC	27
2.3 Marco jurídico	28
2.3.1 Ley N° 31814 que promueve el uso de la inteligencia artificial en favor del desarrollo económico y social del país	28
<b>III. METODOLOGÍA</b>	33

3.1 Enfoque de la investigación	33
3.2 Métodos de la investigación	33
3.3 Diseño de la investigación	33
3.4 Población	34
3.5 Muestra	34
3.6 Operacionalización de la variable de estudio	34
3.6.1 Definición conceptual	35
3.6.2 Definición operacional	36
3.7 Técnica e instrumento de recolección de datos	36
3.7.1 Técnica de recolección de datos	36
3.7.2 Instrumento de recolección de datos	36
3.8 Técnicas de análisis de resultados	37
3.8.1 Técnicas de análisis	37
3.8.2 Proceso estadístico investigativo	44
<b>IV. RESULTADOS Y DISCUSIÓN</b>	46
4.1 Muestra de entrenamiento y validación	46
4.2 Visualización de las tomografías computarizadas del tórax	46
4.3 Modelos de Deep Learning	47
4.3.1 Modelo GoogLeNet	47
4.3.2 Modelo AlexNet	50
4.4 Comparación de modelos	53
<b>V. CONCLUSIONES Y RECOMENDACIONES</b>	54
5.1 Conclusiones	54
5.2 Recomendaciones	54
<b>VI. REFERENCIAS BIBLIOGRÁFICAS</b>	56
<b>ANEXOS</b>	63

## LISTA DE TABLAS

<b>Tabla 1</b> Matriz de confusión	26
<b>Tabla 2</b> Matriz de confusión del modelo GoogLeNet	49
<b>Tabla 3</b> Matriz de confusión del modelo AlexNet	52
<b>Tabla 4</b> Comparación de los modelos de GoogLeNet y AlexNet	53

## LISTA DE FIGURAS

<b>Figura 1</b> Muertes por Covid-19 desde el 17 de marzo de 2020 hasta el 16 de julio de 2022	2
<b>Figura 2</b> Evolutivo del número de casos confirmados de Covid-19 en el Perú	3
<b>Figura 3</b> Evolutivo del número de casos confirmados de Covid-19 en el Perú	4
<b>Figura 4</b> IA, machine learning y deep learning	12
<b>Figura 5</b> Programación clásica	13
<b>Figura 6</b> Machine Learning y un nuevo paradigma de programación	13
<b>Figura 7</b> Modelo de DL para la clasificación de dígitos	15
<b>Figura 8</b> Modelo de DL para la clasificación de dígitos	15
<b>Figura 9</b> Estructura de datos	16
<b>Figura 10</b> Proceso de una Red Neuronal Convolutiva	17
<b>Figura 11</b> Proceso de convolución de Red Neuronal Convolutiva	19
<b>Figura 12</b> Muestreo con Max-Pooling	20
<b>Figura 13</b> Arquitectura de RNC para la detección de imágenes	21
<b>Figura 14</b> Arquitectura de Red Neuronal Convolutiva GoogLeNet	24
<b>Figura 15</b> Arquitectura de Red Neuronal Convolutiva AlexNet	25
<b>Figura 16</b> Imágenes de rayos X de tórax de personas sin covid-19 y con covid-19	35
<b>Figura 17</b> Conjunto de imágenes de las tomografías computarizadas del tórax	37
<b>Figura 18</b> Imágenes de las tomografías computarizadas del tórax en la base de datos de entrenamiento	46
<b>Figura 19</b> Valor de la exactitud del modelo de GoogLeNet según las iteraciones para su entrenamiento	47
<b>Figura 20</b> Errores según las iteraciones de la muestra de entrenamiento del modelo de GoogLeNet	48
<b>Figura 21</b> Exactitud y Errores según las iteraciones de la muestra de entrenamiento del modelo de GoogLeNet	48
<b>Figura 22</b> Curva ROC del modelo de GoogLeNet	49
<b>Figura 23</b> Valor de la exactitud del modelo de AlexNet según las iteraciones para su entrenamiento	50

<b>Figura 24</b> Errores según las Iteraciones de la muestra de entrenamiento del modelo de AlexNet	51
<b>Figura 25</b> Exactitud y Errores según las Iteraciones de la muestra de entrenamiento del modelo de AlexNet	51
<b>Figura 26</b> Curva ROC del modelo de AlexNet	52

## RESUMEN

Las estadísticas de covid-19 reflejaron una gran preocupación a nivel mundial y sobre todo en el Perú. Desde marzo del 2020, el brote de la enfermedad por coronavirus empezó a causar muertes en el Perú frente a un sistema de salud poco preparado para este tipo de situaciones, eso se vio reflejado en la limitación de camas UCI disponibles. Frente a este contexto, el objetivo general de la presente investigación fue determinar el modelo más adecuado de Deep Learning haciendo uso de una arquitectura de Red Neuronal Convolutiva para el diagnóstico de covid-19 empleando tomografías computarizadas de Kaggle. El método de investigación fue hipotético deductivo, con diseño no experimental, transversal, descriptivo y correlacional. La técnica usada para la recolección de datos fue documental, el instrumento fue la plataforma Kaggle y la base de datos del conjunto de imágenes de tomografías computarizadas del tórax. La población de la investigación estuvo conformada por las 15,235 imágenes de tomografías computarizadas del tórax tomadas de la plataforma de datos abiertos de Kaggle, sobre las cuales se determinaron una muestra de entrenamiento y una muestra de validación, 80% y 20%, respectivamente. Se compararon los modelos de Deep Learning de Red Neuronal Convolutiva de AlexNet y GoogLeNet, obteniéndose que el modelo más adecuado para el diagnóstico de covid-19 haciendo uso de tomografías computarizadas del tórax fue el modelo de GoogLeNet, pues obtuvo un valor superior del área bajo la curva ROC de 0.97.

**Palabras claves:** covid-19, tomografía computarizada, Deep Learning, Red Neuronal Convolutiva, AlexNet, GoogLeNet.

## **ABSTRACT**

The covid-19 statistics reflected great concern worldwide and especially in Peru. Since March 2020, the outbreak of the coronavirus disease began to cause deaths in Peru in the face of a health system that was poorly prepared for this type of situation; this was reflected in the limitation of available ICU beds. Against this context, the general objective of the present research was to determine the most appropriate Deep Learning model using a Convolutional Neural Network architecture for the diagnosis of covid-19 using Kaggle computed tomography scans. The research method was hypothetical-deductive, with a non-experimental, transversal, descriptive and correlational design. The technique used for data collection was documentary, the instrument was the Kaggle platform and the database of the set of chest computed tomography images. The research population was made up of 15,235 chest CT images taken from the Kaggle open data platform, on which a training sample and a validation sample were determined, 80% and 20%, respectively. The Convolutional Neural Network Deep Learning models of AlexNet and GoogLeNet were compared, obtaining that the most appropriate model for the diagnosis of covid-19 using computed tomography of the chest was the GoogLeNet model, as it obtained a higher value of the area under the ROC curve of 0.97.

**Keywords:** *covid-19, computed tomography, Deep Learning, Convolutional Neural Network, AlexNet, GoogLeNet.*

## I. INTRODUCCIÓN

La presente investigación aborda el covid-19, que, desde marzo del 2020, las estadísticas en el Perú empezaron a mostrar muertes ante un sistema de salud inadecuado y la limitación de camas UCI. Jesús Valverde, quién fue presidente de la Asociación Peruana de Medicina Intensiva (APMI) comentó que existen 1,400 camas UCI activas en todo el Perú, las cuales, en diciembre de 2020, 1,350 camas UCI se encontraban ocupadas, es decir, más del 90%.

A escala internacional se han llevado a cabo múltiples indagaciones realizando uso de modelos Deep Learning (DL) a fin que se diagnostique el covid-19 a través del uso de imágenes médicas. Bhattacharya et al. (2021), mencionaron que las técnicas de Deep Learning implementadas al procesamiento de imágenes han ganado un gran impulso en la salud. Apostolopoulos y Mpesiana (2020), utilizando una colección de datos de imágenes de rayos X (IRX) de GitHub, Cohen, Radiology Society of North America (RSNA), y la Sociedad Italiana de Radiología Médica e Intervencionista (SIRM) se asociaron y utilizaron una Red Neuronal Convolutiva (RNC) para detectar pacientes con covid-19. Nur-A-Alam et al. (2021), mencionaron que un diagnóstico preciso del covid-19 puede disminuir la tasa de muerte de los pacientes. Chaddad et al. (2020), haciendo uso de tomografías y rayos X (RX) de pacientes usaron Deep Learning y entrenaron diferentes arquitecturas de RNC. Minaee et al. (2020), aplicaron modelos de Deep Learning para detectar pacientes con covid-19 tomando en consideración sus imágenes de radiografía de tórax. Yang et al. (2021), haciendo uso de imágenes radiológicas y tomográficas para la identificación de COVID-19, emplearon modelos de Deep Learning y entrenaron diferentes arquitecturas de RNC. Asimismo, Akter et al. (2021), haciendo uso de un conjunto de datos de IRX del tórax entrenaron modelos de DL de diferentes arquitecturas de RNC.

La investigación busca determinar el modelo más adecuado de DL haciendo uso de una arquitectura de RNC para el diagnóstico de covid-19 empleando tomografías computarizadas de Kaggle. Concretamente, la investigación avala la hipótesis de que el modelo de DL más conveniente hacia el diagnóstico de covid-19 con tomografías computarizadas del tórax es el modelo de RNC

GoogLeNet, el cual presenta un valor superior de 95% en el indicador de sensibilidad y un valor del área bajo la curva ROC superior a 0.95.

## 1.1 Descripción del problema

Las estadísticas de COVID-19 mostraron una gran inquietud a escala global, especialmente en estado peruano. Desde marzo de 2020, el brote de la enfermedad provocó fallecimientos en nuestro país, que contaba con un sistema de salud poco preparado para enfrentar estas circunstancias, lo que se evidenció en la escasez de camas UCI disponibles. En la figura 1, se puede apreciar el número de víctimas por COVID-19 desde marzo de 2020 hasta julio de 2022.

### Figura 1

*Muertes por Covid-19 desde el 17 de marzo de 2020 hasta el 16 de julio de 2022*



*Nota.* Tomado de *Google*, 2022.

Jesús Valverde (2020), quién fue presidente de la APMI, comentó que existen 1,400 camas UCI operativas en todo el Perú, de las cuales, a diciembre de 2020, 1,350 camas UCI se encontraban ocupadas, es decir, más del 90% de ocupación.

Carissa F. Etienne (2022), quién fue directora de la Organización Panamericana de la Salud (OPS) y directora regional de la Organización Mundial de la Salud

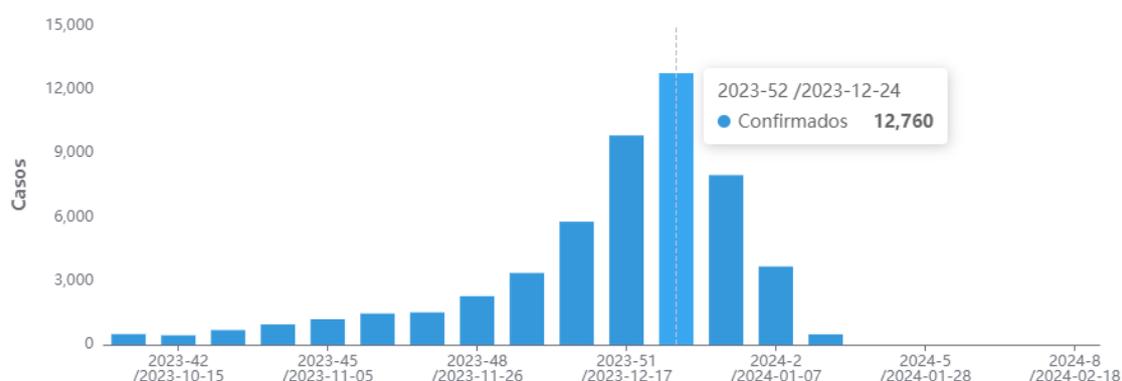
para las Américas desde febrero de 2012 hasta enero de 2023, aludió que la pandemia por Covid-19 ha instaurado un impacto significativo en nuestra vida y sociedad, pero fortaleció la capacidad y el impacto de las tecnologías digitales en beneficio de la salud pública. Asimismo, menciona que los estados que capitalizaron las innovaciones digitales obtuvieron resultados más óptimos en la batalla contra la Covid-19.

Raúl Urquiza (2024), quién es decano del Colegio Médico del Perú, mencionó que la institución que lidera se encuentra alarmada a raíz del acrecentamiento de casos de Covid-19 durante el mes de diciembre de 2023. Explica que esto se debe ante la negativa de la población a completar su esquema de vacunación y la falta de pruebas de descarte en los centros de hospitalarios.

El Centro Nacional de Epidemiología, Prevención y Control de Enfermedades (CDC) del Viceministerio de Salud Pública del Ministerio de Salud del Perú (2024), registró que, durante el mes de diciembre de 2023, la cantidad de casos por Covid-19 alcanzó 39,705. En la figura 2, se puede apreciar que la mayor cantidad de casos documentados por Covid-19 se presentó en la semana 52 del año 2023 con un total de casos de 12,760.

## Figura 2

*Evolutivo del número de casos confirmados de Covid-19 en el Perú*

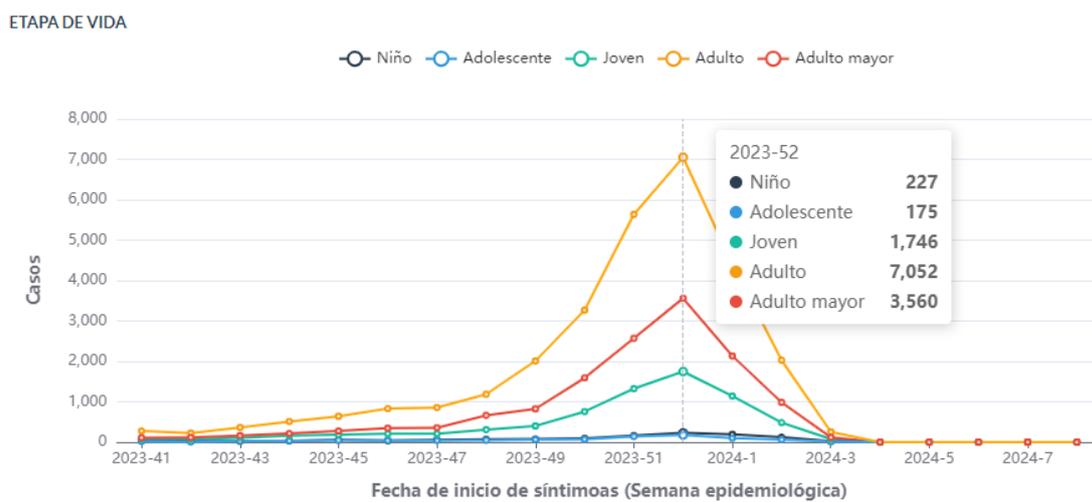


*Nota.* Adaptado de *sala covid*, por el CDC del Viceministerio de Salud Pública del Ministerio de Salud del Perú, 2024, ([https://app7.dge.gob.pe/maps/sala\\_covid/](https://app7.dge.gob.pe/maps/sala_covid/)).

Asimismo, en la figura 3, se muestra que de los 12,760 casos registrados por Covid-19 en la semana 52 del año 2023, 7,052 (55%) se registraron en adultos, 3,560 (28%) en adultos mayores y 1,746 (14%) en jóvenes.

**Figura 3**

*Evolutivo del número de casos confirmados de Covid-19 en el Perú*



*Nota.* Adaptado de *sala covid*, por el CDC del Viceministerio de Salud Pública del Ministerio de Salud del Perú, 2024, ([https://app7.dge.gob.pe/maps/sala\\_covid/](https://app7.dge.gob.pe/maps/sala_covid/)).

Jairo Méndez (2024), quién es asesor regional en enfermedades virales de la OPS, menciona que a 4 años del arribo del Covid-19, se aprendió a confiar en la ciencia y se comprendió que el virus es altamente adaptable, lo que obliga a realizar un monitoreo constante a su evolución. También menciona que no se contaba con las herramientas necesarias para detectarla y hacer un diagnóstico efectivo.

La Organización Mundial de la Salud (2023), hace referencia que cuando la capacidad para llevar a cabo pruebas diagnósticas de COVID-19 es restringida, se debe dar preferencia a las personas con mayor vulnerabilidad a la infección, por ejemplo, personal de salud y personas mayores.

Eduardo Bocarruido (2021), científico de datos del Instituto de Ingeniería del Conocimiento de España, menciona la importancia del uso de modelos de DL

aplicados a la identificación de covid-19, sirviendo como una herramienta muy valiosa para la comunidad médica y complemento a fin de la evaluación y diagnóstico de covid-19.

Luengo-Oroz et al. (2020), mencionó que la inteligencia artificial brinda nuevas herramientas a la medicina para realizar diagnósticos mucho más certeros.

De lo anterior, se deduce la importancia de realizar seguimiento a la evolución del covid-19, acompañado del uso de herramientas innovadoras que ayuden a incorporar nuevas pruebas de diagnóstico. En ese sentido, manejar modelos de Deep Learning como pruebas de diagnóstico que permita identificar a los pacientes con covid-19 mediante el uso de tomografías computarizadas, puede ayudar a la precisión de su determinación y aumentar la eficiencia en la gestión del covid-19.

## **1.2 Formulación del problema**

Las pruebas actuales de covid-19 aplicables para la identificación de pacientes con covid-19 tiene un grado de precisión importante, sin embargo, se pueden complementar empleando modelos de DL haciendo uso de una arquitectura de RNC sobre tomografías computarizadas. Por lo tanto, el problema de la investigación es:

¿Cuál es el modelo más adecuado de Deep Learning haciendo uso de una arquitectura de Red Neuronal Convolutiva para el diagnóstico de covid-19 empleando tomografías computarizadas de Kaggle?

## **1.3 Objetivos**

### **1.3.1 Objetivo General**

Determinar el modelo más adecuado de Deep Learning haciendo uso de una arquitectura de Red Neuronal Convolutiva para el diagnóstico de covid-19 empleando tomografías computarizadas de Kaggle.

### **1.3.2 Objetivos específicos**

Evaluar el desempeño del modelo GoogLeNet para el diagnóstico de covid-19 empleando tomografías computarizadas de Kaggle haciendo uso de los indicadores de sensibilidad y el área bajo la curva ROC.

Evaluar el desempeño del modelo AlexNet para el diagnóstico de covid-19 empleando tomografías computarizadas de Kaggle haciendo uso de los indicadores estadísticos de sensibilidad y el área bajo la curva ROC.

### **1.4 Formulación de la hipótesis**

El modelo de Deep Learning más adecuado para el diagnóstico de covid-19 con tomografías computarizadas del tórax es el modelo de RNC GoogLeNet, el cual presenta un valor superior de 95% en el indicador estadístico de sensibilidad y un valor del área bajo la curva ROC superior a 0.95.

### **1.5 Justificación e importancia**

La justificación teórica de esta investigación radica en que se está utilizando la teoría de la ciencia estadística empleando un modelo de DL con una arquitectura de RNC para el diagnóstico de covid-19, más allá de los métodos actualmente usados, como por ejemplo las pruebas PCR (reacción en cadena de la polimerasa), las cuales tienen limitaciones en recursos de equipos y el tiempo para los resultados.

La justificación práctica de esta investigación es que servirá a las Instituciones Públicas en el Perú como el Ministerio de Salud y EsSalud, en general a los Hospitales del Perú, pues les valdrá como una herramienta a usar en los diferentes hospitales para el diagnóstico de covid-19, siendo sus pacientes los principales beneficiarios. Asimismo, ayudará a los radiólogos a aumentar la precisión de sus diagnósticos, a expertos en cuidados pulmonares intensivos a aumentar la eficiencia en la predicción, en general a profesionales de la salud a identificar pacientes con covid-19, mucho más rápido que pasar por un escaneo

de tomografías computarizadas una por una. El Colegio Médico del Perú también se beneficiará, pues le servirá como un caso de uso para el diagnóstico de covid-19. La actual indagación favorecerá a otros académicos como referencia bibliográfica y caso de aplicación de Deep Learning en la salud. Finalmente, servirá como un instrumento para la toma de decisiones hacia la gestión del covid-19.

La justificación metodológica de esta investigación, está sustentada por Bhattacharya et al. (2021), indicaron que las técnicas de DL, estadísticamente, han ganado una gran relevancia en la salud, asimismo, Nur-A-Alam et.al. (2021), señalaron que un diagnóstico exacto del covid-19 consigue reducir la tasa de muerte mediante la aplicación de esta metodología estadística. Por otro lado, Akter et.al. (2021), mencionaron que los modelos de DL, estadísticamente, presentan una alta precisión en la identificación de personas con covid-19.

Por las razones presentadas, la importancia de la actual investigación reside en que trata de diagnosticar estadísticamente, con la mayor precisión, el covid-19 a partir del uso de tomografías computarizadas empleando la ciencia estadística mediante el uso del modelo de DL con una arquitectura de RNC.

## II. MARCO TEÓRICO

### 2.1 Antecedentes

Bhattacharya et al. (2021), mencionaron que las técnicas de Deep Learning aplicadas al procesamiento de imágenes han ganado un gran impulso en la salud. Apostolopoulos y Mpesiana (2020), haciendo uso de una colección de datos de imágenes de RX de GitHub, Cohen, Radiology Society of North America (RSNA), y la SIRM se asociaron y utilizaron DL mediante Redes Neuronales Convolucionales a fin de detectar pacientes con COVID-19. Ozturk et al. (2020), resalta que el uso de imágenes conduce a una detección más precisa de covid-19 mediante el modelo de DarkNet frente a una escasez de especialistas.

Nur-A-Alam et.al. (2021), mencionaron que un diagnóstico preciso del Covid-19 puede disminuir la tasa de muerte de los pacientes. Para ello, usaron las imágenes de radiografía del tórax de un grupo de pacientes y haciendo uso de DL mediante el adiestramiento de un modelo RNC de VGGNet logró alcanzar una precisión del 99.49% y una sensibilidad de 93.65%.

Chaddad et.al. (2020), haciendo uso de tomografías y RX de pacientes usaron Deep Learning y entrenaron diferentes estructuras de Redes Neuronales Convolucionales, entre las cuales fueron AlexNet, DenseNet, GoogLeNet, NASNet-Mobile, ResNet18 y DarkNet. Al hacer uso de IRX, obtuvieron un AUC del 97% y al combinar los RX con las imágenes computarizadas del tórax el modelo de DarkNet alcanzó una exactitud del 99.09% con un AUC de 99.89%.

Minaee et.al. (2020), aplicaron modelos de DL a fin de detectar pacientes con covid-19 en base de sus imágenes de radiografía de tórax haciendo uso de 5,000 radiografías de tórax. Entrenaron cuatro tipos de arquitectura de Redes Neuronales Convolucionales, RestNet18, ResNet50, SqueezeNet y DenseNet-121. La mayoría de los modelos obtuvo una sensibilidad cercana al 98%.

Yang et.al. (2021), haciendo uso de imágenes médicas de RX y tomografías computarizadas a fin de identificar covid-19, emplearon cuatro modelos de Deep

Learning y entrenaron distintas arquitecturas de arquitectura de Redes Neuronales Convolucionales, entre las cuales fueron VGG16, DenseNet121, ResNet50 y ResNet152. Los modelos obtuvieron una precisión por encima del 96% en la detección de covid-19.

Akter et.al. (2021), haciendo uso de un conjunto de datos de 3,616 IRX del tórax con covid-19 y 10,192 sin covid-19, emplearon once modelos de Deep Learning y entrenaron distintas arquitecturas de arquitectura de Redes Neuronales Convolucionales, entre las cuales fueron VGG16, VGG19, MobileNetV2, InceptionV3, NFNet, ResNet50, ResNet101, DenseNet, EfficientNetB7, AlexNet y GoogLeNet. El modelo MobileNetV2 obtuvo una mayor precisión con un valor del 98% en la identificación de individuos con covid-19.

Pico et.al. (2022), haciendo uso de imágenes de radiografías de tórax proponen el uso de una RNC RESNET34 a fin de categorizar las imágenes con covid-19 y no covid-19, obteniéndose un grado de precisión de 94.78%. La sensibilidad de modelo, a fin de la detección correcta de covid-19, alcanzó un valor de 95.68%. Asimismo, mencionan que el uso de este modelo a fin de detectar pacientes con covid-19 debe usarse como complemento a las pruebas médicas aceptadas por la OMS.

## **2.2 Marco conceptual**

### **2.2.1 Covid-19**

La Organización Mundial de la Salud (OMS) afirma que el nuevo coronavirus identificado como SARS-CoV-2 es el origen del Covid-19. Esta organización recibió la notificación de varias ocurrencias de neumonía vírica que se habían notificado en Wuhan (República Popular China) el 31 de diciembre de 2019, que es cuando tuvo conocimiento por primera vez de la presencia de este nuevo virus.

Asimismo, según la OMS, los individuos que despliegan síntomas, la mayoría se restablecen de la enfermedad sin requerir atención hospitalaria. Hay un rango de

1 a 14 días, aunque la duración media desde la exposición al covid-19 hasta la aparición de los síntomas es de 5 a 6 días. El 15% de las personas contraen una enfermedad grave que necesita oxígeno, y el 5% llega al punto de necesitar cuidados críticos. La insuficiencia respiratoria, el síndrome de distrés respiratorio multiorgánico (que contiene anomalías cardíacas, hepáticas y renales) y la insuficiencia respiratoria son algunas de las complicaciones que pueden ser mortales.

### **2.2.2 Prueba para el diagnóstico de covid-19**

Según la OMS, cualquier individuo que presente síntomas como fiebre alta, tos y que han tenido contacto con alguien infectado, debería hacerse una prueba para la detección del covid-19, con el objetivo de que pueda recibir la atención médica adecuada.

### **2.2.3 Tipos de prueba para el diagnóstico de covid-19**

La OMS menciona que hay dos tipos de pruebas a fin de diagnosticar a una persona infectada con el virus SARS-CoV-2, que origina el covid-19. Las evaluaciones son las moleculares y las rápidas de antígenos.

Las pruebas moleculares, como la reacción en cadena de la polimerasa (PCR), las cuales son las pruebas más exactas, identifican el virus en la muestra al amplificar el material genético viral hasta escalas detectables.

Las pruebas rápidas de antígenos (igualmente determinadas como pruebas de diagnóstico rápido o PDR) identifican proteínas virales (denominadas antígenos). Estas pruebas son más efectivas cuando hay una mayor circulación del virus en la comunidad y se realizan en individuos en el transcurso del período en que el virus es más contagioso, usualmente en los primeros 5 a 7 días tras la manifestación de los síntomas.

Las muestras para uno y otro tipo de prueba se acopian de la nariz y/o garganta usando un hisopo.

#### **2.2.4 Tomografía computarizada del tórax**

En RadiogyInfo, se menciona que la tomografía computarizada del tórax usa un equipo específico de RX a fin de inspeccionar anomalías halladas en otros exámenes por imágenes.

Larissa Hirsch (2022), menciona que una tomografía computarizada del tórax es una clase de prueba de imágenes, la cual usa computadoras y máquinas giratorias de RX, brindando imágenes más minuciosas de los pulmones, el corazón, los vasos sanguíneos, las vías respiratorias, las costillas y los ganglios linfáticos del paciente, que las que pueden proporcionar los RX. La tomografía computarizada torácica puede detectar indicios de inflamación, infección, daño o enfermedad en los pulmones, las vías respiratorias, el corazón, los grandes vasos sanguíneos, los ganglios linfáticos y el esófago.

Wu et.al. (2020), presentan que una de las herramientas que ayudan en el diagnóstico y evaluación del covid-19 es la tomografía computarizada, la cual muestra lesiones pulmonares.

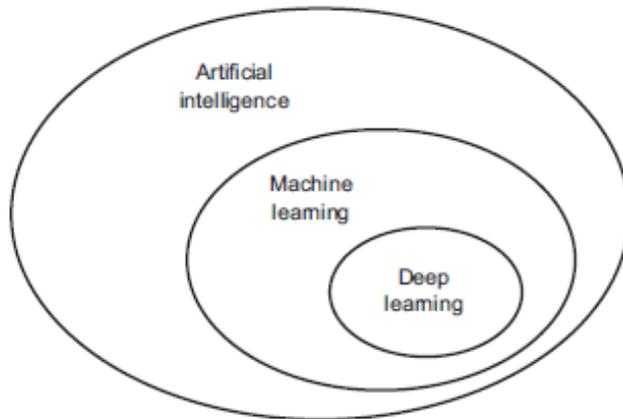
Soriano et.al. (2021), mencionan la importancia de hacer uso de tomografías computarizadas del tórax de los pacientes para evaluar las afecciones pulmonares presentadas por el covid-19.

#### **2.2.5 Inteligencia Artificial**

La inteligencia artificial (IA) surgió en la década de 1950, en el momento en un grupo reducido de precursores del nascente ámbito de la informática empezó a interrogarse si se podían fabricar ordenadores para “pensar”. Una delimitación concisa del campo sería el siguiente: el intento por automatizar labores intelectuales regularmente realizadas por individuos. Como tal, la inteligencia artificial es un ámbito general que comprende el machine learning (ML) y DL. En la figura 4, se muestra cómo se relacionan estos tres términos (Chollet, 2018, Capítulo 1, p. 4).

## Figura 4

*IA, machine learning y deep learning*



*Nota.* Tomado de *DL with Python* (p. 4), por F. Chollet, 2018, Manning.

Por ejemplo, los primeros algoritmos de ajedrez no cumplían los criterios del aprendizaje automático, ya que sólo incluían reglas programadas desarrolladas por programadores. Durante mucho tiempo, algunos especialistas opinaron que los programadores podían crear una inteligencia artificial comparable a la humana creando un conjunto suficientemente amplio de reglas explícitas a fin de maniobrar el conocimiento. Inteligencia artificial simbólica es el término que designa este método, que dominó el campo desde los años 50 hasta la última etapa de los 80. En la década de los 80, durante el auge de los sistemas expertos, alcanzó su máxima popularidad (Chollet, 2018, Capítulo 1, p. 4).

Aunque la inteligencia artificial simbólica manifestó ser conveniente a fin de disipar dificultades lógicas bien determinados, como jugando al ajedrez, fue complicado hallar reglas explícitas a fin de disipar inconvenientes más complejos y confusos, a manera de categorización de imágenes, reconocimiento de voz y traducción del lenguaje. Por lo que emergió un nuevo rumbo a fin de ocupar el lugar de la IA simbólica, denominada el aprendizaje adaptativo o ML (Chollet, 2018, Capítulo 1, p. 4).

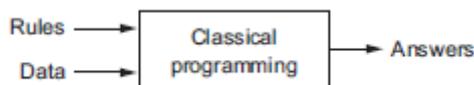
## 2.2.6 Machine Learning

El aprendizaje automático brota de esta interrogante: ¿podría una computadora ir más allá de lo que sabe cómo para ordenarle efectúe y aprenda por sí solo cómo efectuar una tarea particular? ¿Podría una computadora maravillarnos? En el sitio en que los especialistas de programación diseñen sistemas de manejo de datos bajo reglas a mano, ¿podría una computadora aprenderlas instintivamente al observar los datos? Estas preguntas apertura un nuevo paradigma de programación (Chollet, 2018, Capítulo 1, p. 5).

En la programación clásica, el paradigma de la inteligencia artificial simbólica, los individuos ingresan pautas y datos a fin de ser procesados para obtener respuestas, como se exhibe en la figura 5 (Chollet, 2018, Capítulo 1, p. 5).

**Figura 5**

*Programación clásica*

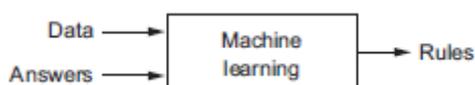


*Nota.* Tomado de *DL with Python* (p. 5), por F. Chollet, 2018, Manning.

Con ML o aprendizaje automático, los individuos ingresan datos, así como las respuestas deseadas de los datos y se obtienen reglas. Estas reglas alcanzan luego emplearse a nuevos datos a fin de obtener respuestas originales, como se aprecia en la figura 6 (Chollet, 2018, Capítulo 1, p. 5).

**Figura 6**

*Machine Learning y un nuevo paradigma de programación*



*Nota.* Tomado de *DL with Python* (p. 5), por F. Chollet, 2018, Manning.

En lugar de codificarse explícitamente, un sistema de ML aprende utilizando ejemplos significativos para la tarea y una estructura estadística para producir reglas que automaticen la actividad. Por ejemplo, usted podría utilizar un sistema de aprendizaje automático que utilizara fotografías previamente etiquetadas para automatizar el proceso de etiquetado de las fotos de sus vacaciones. A continuación, el sistema utilizaría estas etiquetas preexistentes para identificar las imágenes basándose en principios estadísticos (Chollet, 2018, Capítulo 1, p. 5).

Aunque el ML empezó a prosperar recién en el período de 1990, velozmente se convirtió en el subcampo más destacado y célebre de la Inteligencia Artificial, una propensión fomentada por la accesibilidad del hardware más vertiginoso y conjuntos de datos más extensas. El ML está intrínsecamente vinculado a la estadística matemática, sin embargo, se opone a la estadística en diversas apariencias valiosos. A diferencia de las estadísticas, el ML tiende a trabajar con conjuntos de datos extensas y complicados (como un conjunto de datos de millones de imágenes, cada una de las cuales se constituye de decenas de miles de píxeles) hacia cuyo análisis estadístico clásico, como el análisis bayesiano, sería impensable (Chollet, 2018, Capítulo 1, p. 6).

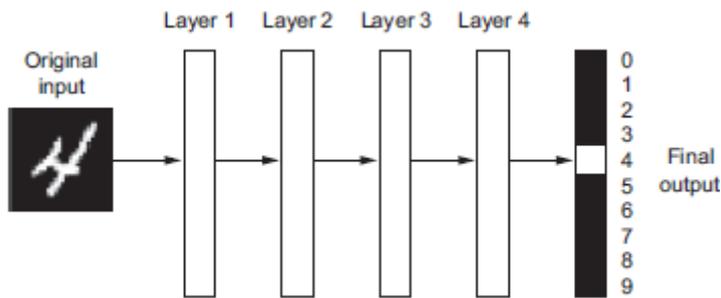
### **2.2.7 Deep Learning**

DL es un subcampo del ML, que destacan la enseñanza de capas sucesivas de conocimientos cada vez más significativas. Lo profundo en el deep learning incorpora esta idea de sucesivas capas de representaciones. ¿Cuántas capas apoyan a un modelo de datos? llamada profundidad del modelo. En DL, estas conceptualizaciones en capas se asimilan a través de modelos denominados redes neuronales artificiales, estructurados en capas literales acopiadas una encima de otra. Para nuestros propósitos, DL es un marco matemático hacia las representaciones de aprendizaje desde los datos (Chollet, 2018, Capítulo 1, p. 8).

En la figura 7, se muestra como una red neuronal de varias capas de profundidad transforma una imagen de un dígito a fin de poder reconocer de qué dígito se trata.

**Figura 7**

*Modelo de DL para la clasificación de dígitos*



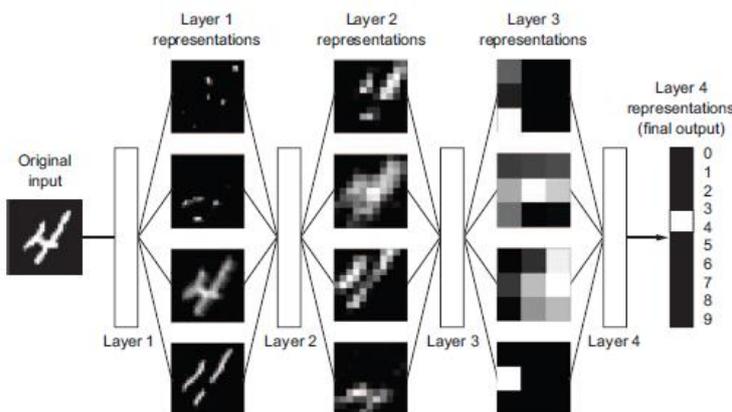
*Nota.* Tomado de *DL with Python* (p. 9), por F. Chollet, 2018, Manning.

Asimismo, en la figura 8, la red convierte la imagen de los dígitos en caracteres que son cada vez más desiguales de la imagen original y más informativos acerca del efecto final, en el cual la información pasa por filtros sucesivos y sale cada vez más purificado (O sea, ventajoso respecto a cualquier tarea).

Eso es, técnicamente, el deep learning, una forma de varias etapas de instruir representaciones de datos. Es una idea simple, mecanismos muy simples, suficientemente escalado (Chollet, 2018, Capítulo 1, p. 9).

**Figura 8**

*Modelo de DL para la clasificación de dígitos*



*Nota.* Tomado de *DL with Python* (p. 9), por F. Chollet, 2018, Manning.

Voulodimos et al. (2017), mencionan que El aprendizaje profundo facilita modelos informáticos con varias capas de procesamiento a fin de aprender y representar datos con múltiples grados de abstracción que imitan cómo el cerebro percibe y comprende información multimodal, capturando implícitamente arreglos de datos a gran escala. Esto va muy de la mano con el empoderamiento de la computación GPU paralela, lo cual permitió la migración del entrenamiento de CPU a GPU.

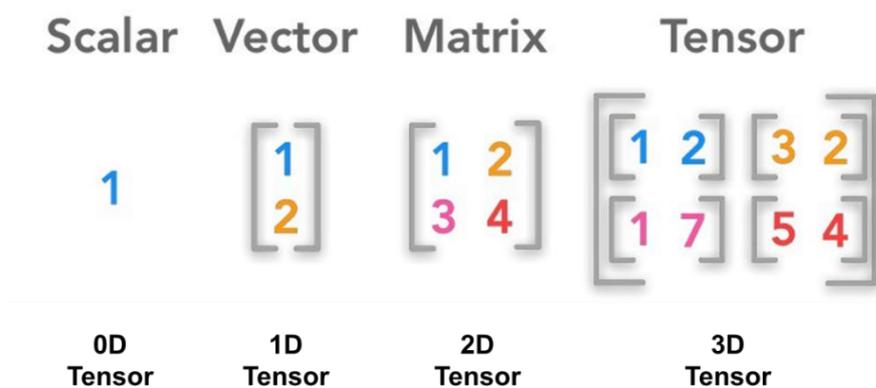
Deep Learning ha avanzado en diferentes aplicaciones, por ejemplo, la detección de objetos, rastreo de movimientos, reconocimiento de acciones y segmentación semántica. Uno de los tipos de modelos más usados en Deep Learning son los modelos de Redes Neuronales Convolucionales.

DL es una técnica de ML, que trabaja con redes neuronales artificiales y presenta una arquitectura con múltiples capas ocultas (Trusculescu et al., 2020). Artola (2019) y Sarmiento (2020), mencionaron que los modelos de DL son muy usados en el reconocimiento de imágenes.

En Deep Learning, los datos se almacenan en arrays multidimensionales o tensores. En la figura 9, se muestra la diferencia entre un escalar, a vector, una matriz y un tensor.

**Figura 9**

*Estructura de datos*



*Nota.* Tomado de *Deep Learning Book Series*, por J. Hadrien, 2018, (<https://hadrienj.github.io/posts/Deep-Learning-Book-Series-2.1-Scalars-Vectors-Matrices-and-Tensors/>).

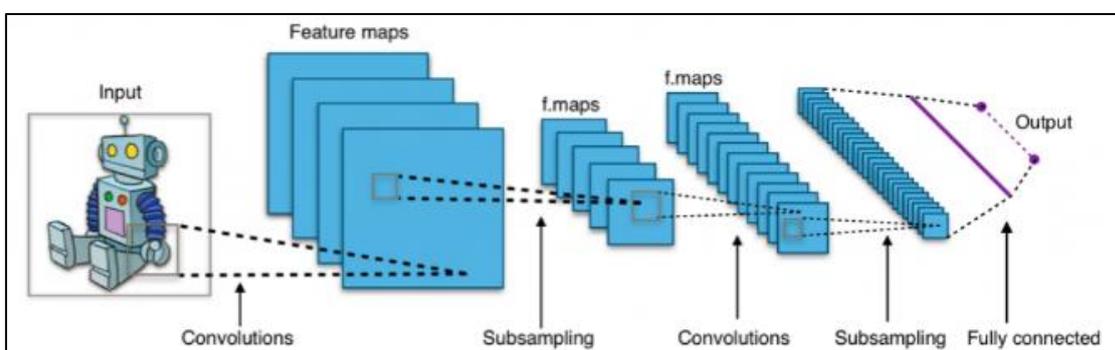
### 2.2.8 Redes Neuronales Convolucionales

Una RNC es uno de los algoritmos más conocidos del Deep Learning, ya que este es un ejemplo de aprendizaje automático en el cual el fin principal es la clasificación de imágenes, videos, textos o incluso sonidos permitiendo la detección de patrones que finalmente permiten a los investigadores ahorrarse el trabajo de extraer las características de manera manual (Maeda, 2019).

En la figura 10, se puede apreciar la forma en la que trabaja una RNC se puede apreciar que toma áreas reducidas de la imagen denominado cuadrado de pixeles, los cuales cumplen el rol de la entrada. Luego este cuadro pasa por un número determinado de capas ocultas organizadas. En este proceso, las primeras capas identifican características como líneas, curvas, bordes, entre otros, siendo las capas más hondas las que pueden identificar la imagen con mayor certeza. Por lo tanto, a un mayor número de capas mejor será la precisión para la identificación de imágenes (Lis Data Solutions).

**Figura 10**

*Proceso de una Red Neuronal Convolutiva*



*Nota.* Tomado de *DL, redes neuronales y visión artificial*, por Lis Data Solutions, (<https://www.lisdatasolutions.com/es/blog/deep-learning-redes-neuronales-y-vision-artificial/>).

Hubel y Wiesel (1962), mencionaron que las RNC se inspiraron en la organización del sistema visual. Por otro lado, Fukurishima (1980), resalta la importancia de los incipientes modelos de redes neuronales. Es así que, LeCun et al. (1989, 1998 y 2016) diseñaron posteriormente las Redes Neuronales Convolucionales que manejan el gradiente de error alcanzando buenas derivaciones en tareas de reconocimiento de patrones y éxito en aplicaciones como reconocimiento facial y autos autónomos.

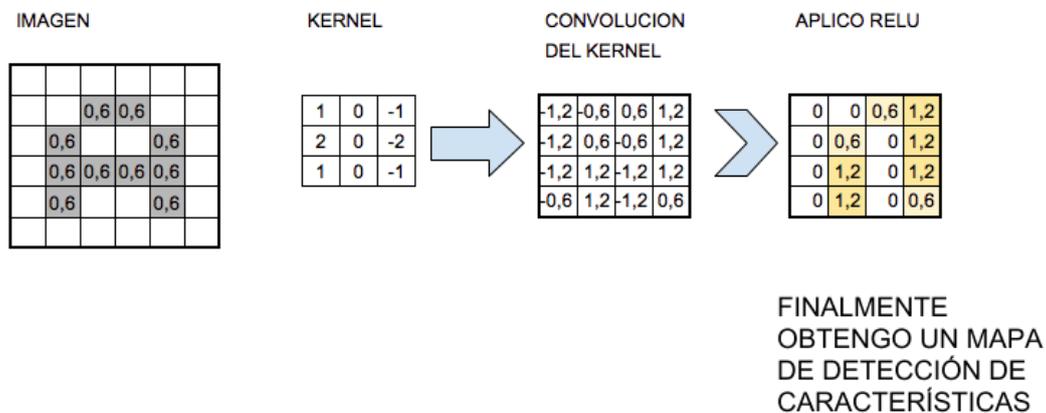
Las redes neuronales convolucionales presentan tres capas:

- i) Capa convolucional. En Voulodimos et.al. (2017), es una de las capas principales y se menciona que, en las capas convolucionales, una RNC usa varios núcleos para convertir la imagen completa, al igual que los mapas de características intermedias, creando diversos mapas de características. Oquab et al. (2015) y Szegedy et al. (2015), han propuesto a la convolución como una alternativa a las capas densamente conectadas para lograr un aprendizaje más ágil.

En la figura 11, se exterioriza el proceso que se desarrolla en la capa convolucional que realiza una RNC. Se puede apreciar que todo inicia, con una imagen de pixeles, la cual es tomada por la red como entrada, estos valores han sido convertidos en valores entre 0 y 1 después de dividirlos entre 255, esto debido a que los pixeles capturan valores entre 0 y 255. Luego se continua con el proceso de convoluciones, que radica en operar montones de pixeles colindantes de la imagen de entrada e ir aplicando un producto escalar con una matriz denominada kernel, el cual permite generar una nueva imagen de salida, que cumplirá el rol de una nueva capa oculta. Finalmente, al resultado de la convolución, se le destina una función de activación no lineal, por lo general la función ReLu.

**Figura 11**

*Proceso de convolución de Red Neuronal Convolutiva*



*Nota.* Tomado de *Redes Neuronales Convolutivas*, por J. Barrios, (<https://www.juanbarrios.com/redes-neurales-convolutivas/>).

La función de activación ReLu (Unidad lineal rectificada), se expresa de la siguiente manera:

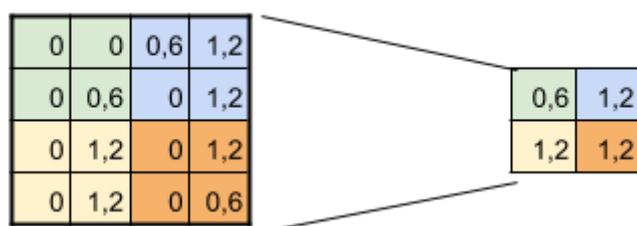
$$f(x) = \max(0, x)$$

- ii) Capa pooling. En Voulodimos et.al. (2017), se menciona que estas capas con las encargadas de disminuir la anchura y la altura del volumen de entrada para que la consecutiva capa convolutiva pueda utilizarlo. La dimensión de profundidad del volumen no se ve afectada por la capa de agrupación. Esta capa también realiza una acción conocida como “downsampling” o “undersampling”, ya que al reducirse se produce una pérdida simultánea de información. No obstante, la red se beneficia de este tipo de pérdida, ya que la contracción reduce la carga computacional de las capas posteriores de la red y evita el sobreajuste. Las dos técnicas de agrupación más populares son la agrupación máxima y la agrupación media Boureau et al. (2010), presenta una descripción teórica detallada del análisis de los rendimientos de agrupación máxima y media.

En la figura 12, se presenta el muestreo de Max-Pooling con tamaño de 2x2 que se utiliza en el proceso que se desarrolla en la capa pooling de una RNC. Este muestreo implica tomar una muestra representativa de las neuronas para luego hacer una siguiente convolución aplicación la función máxima entre los valores. Otra alternativa sería la función Average-Pooling, que en este caso aplica el promedio de los valores.

**Figura 12**

*Muestreo con Max-Pooling*



**SUBSAMPLING:**

Aplico Max-Pooling de 2x2  
y reduzco mi salida a la mitad

*Nota.* Tomado de *Redes Neuronales Convolucionales*, por J. Barrios, (<https://www.juanbarrios.com/redes-neurales-convolucionales/>).

- iii) Capa fully-connected. Esta capa es la última en un modelo de RNC. La neurona en una capa completamente conectada tiene vínculos completos con todas las activaciones en la capa anterior. Su activación, por lo cual, se consigue calcular con una multiplicación de matriz seguida por una compensación de sesgo. Krizheysky et al. (2012) y Girshick et al. (2014), mencionan que las capas completamente conectadas convierten los mapas de características 2D en un vector de características 1D.

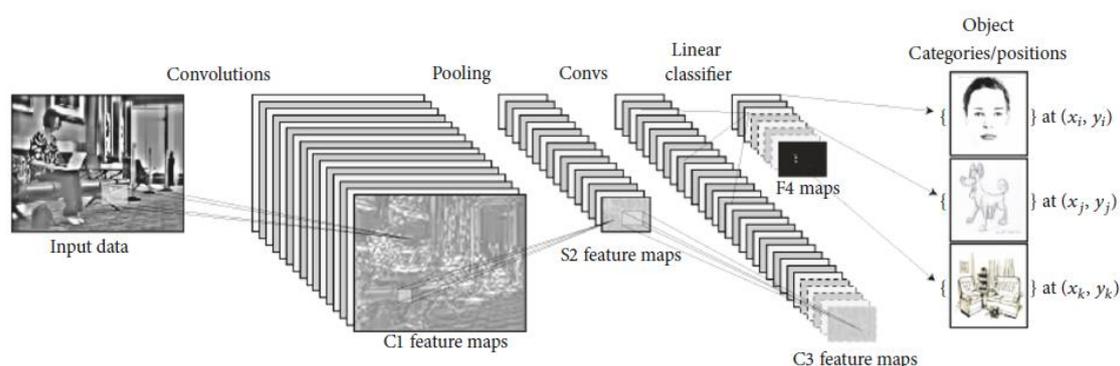
En esta capa mediante la ayuda de un clasificador se establece la clase a la que incumbe cada una de las imágenes de entrada. Esta capa está conectada automáticamente posterior de la capa de pooling

y está compuesta por un número igual de neuronas y de clases (Duran & Del Real, 2017).

En la figura 13, se muestra una arquitectura de una RNC hacia la detección de imágenes conformada por las tres capas descritas en la parte superior.

**Figura 13**

*Arquitectura de RNC para la detección de imágenes*



*Nota.* Tomado de *DL for Computer Vision: A Brief Review* (p. 3), por oulodimos et.al, 2017, Hindawi.

En Voulodimos et.al. (2017), presenta que la arquitectura de una RNC emplea tres conceptos concretos: campos receptivos locales, pesos vinculados y submuestreo espacial. Basado en el campo receptivo local, cada unidad en la capa convolucional recibe entradas de un conjunto de unidades vecinas pertenecientes a la capa anterior. De esta manera, las neuronas son capaces de extraer características visuales primordiales como bordes o esquinas. Luego, estas características se combinan mediante las siguientes capas convolucionales para detectar un orden superior de características. Las unidades de una capa convolucional se establecen en planos, por lo que cada plano es responsable para construir una característica específica. Las salidas de los planos se denominan mapas de características. Cada convolución consta de varios planos, de modo que pueden construirse en cada lugar.

Durante la construcción de un mapa de características, toda la imagen es escaneada por una unidad cuyos estados se almacenan en el correspondiente

mapa de características. Esta construcción es parecida a una operación de convolución, seguida de un término de sesgo aditivo y función sigmoidea:

$$y^{(d)} = \sigma(Wy^{(d-1)} + b)$$

Donde:

d: es la profundidad de la capa convolucional

W: es la matriz de pesos

b: es un término de sesgo

La matriz de pesos W, tiene la forma:

$$[w \ \dots \ 0 \ \vdots \ \vdots \ 0 \ \dots \ w]$$

Donde:

w: son matrices que tienen las mismas dimensiones con los campos receptivos de las unidades.

Si la capa entrada de la capa convolucional d-1 es de dimensión N y el campo receptivo de unidades en un plano de capa convolucional d es mxm, entonces el mapa de características construido será una matriz de dimensiones (N-m+1)x(N-m+1), entonces el elemento de mapa de característica en la locación (i, j) será:

$$y_{ij}^{(d)} = \sigma(x_{ij}^{(d)} + b)$$

Con:

$$x_{ij}^{(d)} = \sum_{\alpha=0}^{m-1} \sum_{b=0}^{m-1} \omega_{\alpha b} y_{(i+\alpha)(j+b)}^{(d-1)}$$

Donde:

b: es un término escalar

### **2.2.9 Arquitectura de Red Neuronal Convolutacional GoogLeNet**

La arquitectura de GoogLeNet es una RNC profunda que consigna de 22 capas, si contamos las capas de agrupación serían en total 27 capas. Este tipo de RNC posee tres secciones, la primera es la sección convolutacional, la segunda hace referencia a los módulos de inspección y la última es la salida de la red.

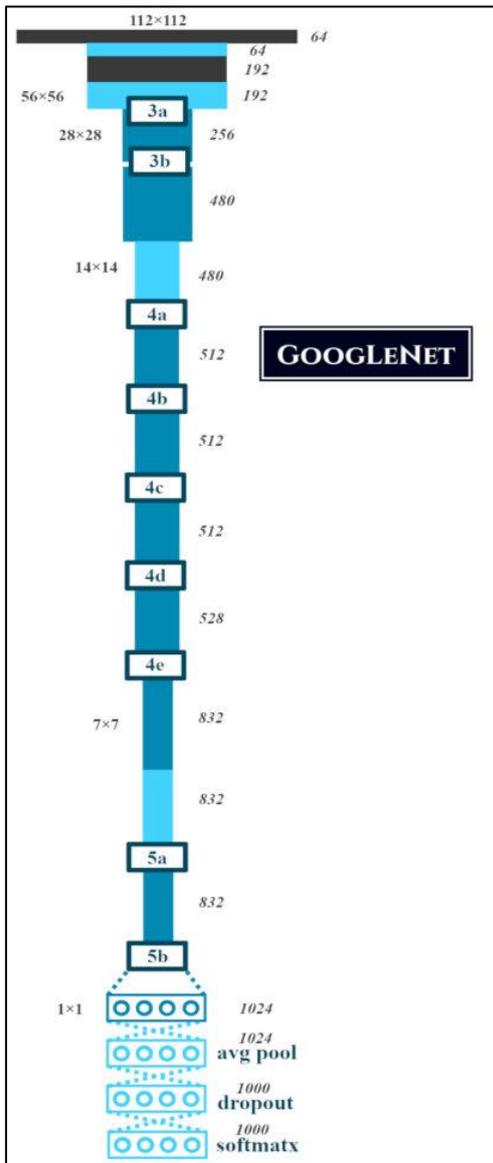
La sección convolutacional está compuesta de 2 capas convolutacionales ordinarias acompañadas de capa de Max-Pooling. En la subalterna sección se encuentran mutuamente tres bloques de dos, cinco y dos módulos de inspección correspondientemente. Estos tres bloques se encuentran apartados uno del otro por medio de una capa de Max-Pooling. La última capa de inspección ocasiona 1.024 mapas de extensiones de 7x7. Finalmente, en la sección de salida se encuentran una capa de Average-Pooling, otra de apagado de un 40% de las neuronas y una última capa con función una de activación softmax, que es la que efectúa la categorización.

En la totalidad de las capas de convolución, las neuronas son unidades haciendo uso de la función ReLu. La función de desgaste es la entropía cruzada, como habitual acontecer en las redes dedicadas a la categorización de objetos (Richmond, 2020).

En la figura 14, se logra observar la arquitectura de la RNC GoogLeNet.

**Figura 14**

*Arquitectura de Red Neuronal Convolutiva GoogLeNet*



*Nota.* Tomado de *Deep Learning: GoogLeNet Explained*, por R. Alake, 2020, (<https://towardsdatascience.com/deep-learning-googlenet-explained-de8861c82765/>).

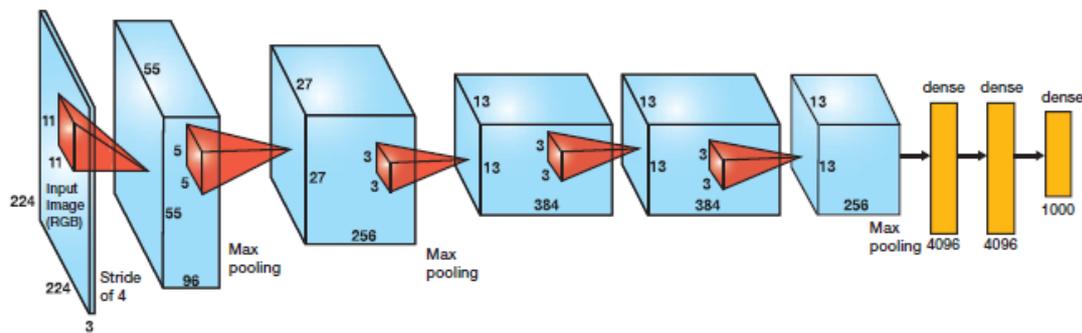
### 2.2.10 Arquitectura de Red Neuronal Convolutiva AlexNet

La arquitectura de AlexNet es una RNC profunda que contiene ocho capas en total, las cinco originarias capas son convolucionales y las tres capas restantes están totalmente conectadas. En la figura 15, se puede apreciar la arquitectura de Neuronal Convolutiva del modelo AlexNet.

Las dos capas iniciales convolucionales están conectadas a capas de agrupación máxima superpuestas para extraer una cantidad máxima de características. Las capas convolucionales tercera, cuarta y quinta están directamente conectadas a las capas completamente conectadas. Todas las salidas de las capas convolucional y completamente conectada están conectadas a la función de activación no lineal ReLu, la cual permite un entrenamiento mucho más rápido. La capa de salida final está conectada a una capa de activación softmax, que provoca una distribución de 1000 etiquetas de clase (Krizhevsky, Sutskever, & Hinton, 2014).

**Figura 15**

*Arquitectura de Red Neuronal Convolucional AlexNet*



*Nota.* Tomado de *ResNet, AlexNet, VGGNet, Inception: Understanding various architectures of Convolutional Networks*, por CV-Tricks, (<https://cv-tricks.com/cnn/understand-resnet-alexnet-vgg-inception/>).

**2.2.11 Matriz de confusión**

Esta matriz ejemplifica la repartición de valores registrados y calculados. Los valores medidos son los valores reales y calculados se derivan del uso de un modelo predictivo, para el caso de la investigación será el modelo Deep Learning de RNC. Por otro lado, El potencial del modelo para identificar el evento de interés con un valor de 1 se conoce como sensibilidad. En cambio, la habilidad del modelo para no identificar el evento de interés con un valor de 0 se llama especificidad. Para la actual indagación se empleará la sensibilidad como medida de exactitud del modelo de Deep Learning de RNC.

**Tabla 1***Matriz de confusión*

Observado	Pronosticado			
	Evento		Porcentaje correcto	
	0	1		
Evento	0	a	b	$a/(a+b)$
	1	c	d	$d/(c+d)$
Exactitud				$(a+d)/(a+b+c+d)$

La descripción de los términos en la matriz de confusión, es el sucesivo:

- a: es el número de predicciones correctas de clase 0 o llamada también negativa, por lo que recibe el nombre de negativos reales.
- b: es el número de predicciones incorrectas de clase 1 o llamada también positiva, por lo que recibe el nombre de falsos positivos.
- c: es el número de predicciones incorrectas de clase 0 o llamada también negativa, por lo que recibe el nombre de falsos negativos.
- d: es el número de predicciones correctas de clase 1 o llamada también positiva, por lo que recibe el nombre de positivos reales.

En una matriz de confusión, frente a un evento en particular que presente dos opciones éxito (1) y fracaso (0), el valor de la sensibilidad, especificidad y exactitud se deducen de la siguiente forma:

- Sensibilidad =  $d/(c+d)$ , revela la facultad que posee un modelo a fin de organizar acertadamente la categoría de interés de la variable dependiente.
- Especificidad =  $a/(a+b)$ , muestra la amplitud que posee un modelo a fin de organizar acertadamente la categoría que no es de interés de la variable dependiente.
- Exactitud =  $(a+d)/(a+b+c+d)$ , revela la facultad que posee un modelo a fin de organizar correctamente de manera global la variable dependiente. El complemento de la exactitud es el error del modelo.

El modelo quemuestre mayor sensibilidad es el modelo más conveniente.

Inca et.al. (2022), mencionaron que el uso de la matriz de confusión es un método útil a fin de valorar la eficiencia de la calidad de predicción del covid-19.

### **2.2.12 Curva ROC**

La curva Receiver Operating Characteristic (ROC) muestra que el método diagnóstico es mejor cuanto más alejado esté de la diagonal principal (es decir, la curva ROC ideal tendría una especificidad de 1 y una sensibilidad de 1), y peor será el método diagnóstico cuanto más cerca esté de esta diagonal. Según Pérez (2015), la diagonal principal tiene un área bajo la curva de 0,5 e incumbe a la prueba diagnóstica más pobre. Además, los intervalos hacia los valores de la curva ROC se han establecido de la siguiente manera:

- [0.5 - 0.6>: Test malo
- [0.6 - 0.75>: Test regular
- [0.75 - 0.9>: Test bueno
- [0.9 - 0.97>: Test muy bueno
- [0.97 - 1>: Test excelente

Se trazan las consecutivas hipótesis:

H0: el área bajo la curva ROC es igual a 0.5

H1: el área bajo la curva ROC no es igual a 0.5

Si se refuta Ho asociado a un p-valor involucra que el modelo ajustado es el adecuado.

Inca et.al. (2022), mencionaron que el uso de la curva ROC es un método útil a fin de evaluar la eficiencia de la calidad de predicción del covid-19.

## **2.3 Marco jurídico**

### **2.3.1 Ley N° 31814 que promueve el uso de la inteligencia artificial en favor del desarrollo económico y social del país**

Esta ley se publicó El 5 de julio de 2023, la ley fomenta la utilización de la IA a fin de potenciar el progreso económico y social del estado en el contexto del proceso nacional de transformación digital. Esta ley establece un conjunto de principios para el impulso y uso de IA en la mejora de los servicios públicos, educación, salud, justicia, seguridad ciudadana, entre otros.

El título preliminar de la ley presenta el siguiente artículo:

Artículo único. Principios para el desarrollo y uso de la inteligencia artificial

Son principios hacia el desarrollo y uso de la IA:

- a) Estándares de seguridad basados en riesgos: Se fomenta un enfoque fundado en riesgos hacia el uso y adelanto de la IA.
  
- b) Enfoque de pluralidad de participantes: Fomenta la cooperación de personas físicas y jurídicas, así como de organizaciones e instituciones públicas y privadas, en el debate en torno a la creación de leyes destinadas a controlar la aplicación de la IA en la nación.
  
- c) Gobernanza de internet: Para definir cómo utilizan Internet el Estado, las instituciones del sector comercial y los miembros de la sociedad civil, fomenta la creación y aplicación de principios, normas, reglamentos, procesos de toma de decisiones y programas.
  
- d) Sociedad digital: Fomenta la aptitud, la innovación, la educación, la identidad digital, la seguridad, la confianza y el uso de las tecnologías emergentes hacia el bienestar social y económico de los ciudadanos. También valora la información

y el discernimiento adquiridos por medio del acceso, el uso y el desarrollo de las tecnologías digitales en todos sus espacios.

e) Desarrollo ético hacia una IA responsable: A la hora de definir con precisión el marco de obligaciones en el uso de este prototipo de sistemas que integran la Industria 4.0, se considera que la ética es el fundamento esencial.

f) Privacidad de la IA: La IA tiene que comportarse de forma segura a fin de optimizar el bienestar de los ciudadanos, pero tampoco puede violar la intimidad de las personas.

El capítulo I de la ley hace referencia a las disposiciones generales y presenta los siguientes artículos:

#### Artículo 1. Objeto de la Ley

Con el fin de beneficiar el progreso económico y social de la nación, esta ley tiene como objetivo fomentar el uso de la IA en el marco del proceso de transformación digital de la nación, prevaleciendo a la persona y defendiendo los derechos humanos en un contexto indudable que avale su uso ético, sostenible, transparente, replicable y responsable.

#### Artículo 2. Interés nacional

El impulso y la aplicación de la IA a fin de mejorar los servicios públicos, la educación y el aprendizaje, la salud, la justicia, la seguridad ciudadana, la seguridad digital, la economía, la inclusión, los programas sociales, la seguridad y la defensa nacional, así como para cualquier otra actividad económica y social a nivel nacional, es de interés nacional, así como el fomento del talento digital en el uso de las tecnologías emergentes y las nuevas tecnologías para el bienestar social y económico.

### Artículo 3. Definiciones

a) Inteligencia artificial: Tecnología emergente de uso frecuente que podría impulsar la productividad y la creatividad, Facilitar la solución de los trascendentales inconvenientes mundiales, promover una actividad económica mundial positiva y sostenible y mejorar la calidad de vida de los individuos.

b) Sistema basado en IA: Sistema electrónico-mecánico que alcanza influir en el entorno virtual o real haciendo predicciones, recomendaciones o tomando decisiones basadas en un conjunto de propósitos concretados por el ser humano. Está pensado a fin de que funcione con distintos grados de independencia.

c) Tecnologías emergentes: La Industria 4.0, que armoniza técnicas adelantadas de producción y operaciones con la tecnología, está formada por tecnologías digitales que pueden producir soluciones novedosas como la robótica, la analítica, la IA, las tecnologías cognitivas, la nanotecnología, el internet de las cosas (IoT) y análogos. Estas tecnologías repercuten en las personas, las organizaciones y el ecosistema digital.

d) Algoritmo: un conjunto de directrices y procesos estructurados y limitados a fin de solventar un inconveniente o llegar a una conclusión.

El capítulo II de la ley hace referencia a la autoridad nacional y presenta los siguientes artículos:

### Artículo 4. Autoridad Nacional

La autoridad técnico-normativa a nivel del estado para dirigir, evaluar y supervisar el uso e impulso de la IA y las tecnologías emergentes para adquirir los objetivos de la nación en materia de transformación digital y desarrollo sostenible en cumplimiento de la legislación vigente es la Presidencia del Consejo de Ministros, actuando a través de la Secretaría de Gobierno y

Transformación Digital, que es el órgano rector del Sistema Nacional de Transformación Digital.

La Autoridad Nacional, dentro del contexto de la transformación digital, implementa y coordina iniciativas para fomentar y fortalecer:

- a) El desarrollo de la IA y su aceptación como una herramienta que estimule el desarrollo y el bienestar del país.
- b) La formación de profesionales con competencia a fin de aprovechar, el desarrollo y usos de la IA en el país.
- c) La creación y el fortalecimiento de la infraestructura digital como habilitadora a fin de lograr el impulso de la IA.
- d) El desarrollo de una infraestructura de datos a fin de poner a disposición datos públicos de alta calidad, reutilizable y accesible.
- e) La adopción de lineamientos éticos a fin de un uso sostenible, transparente y replicable de la IA.
- f) Un ecosistema de colaboración de IA a nivel nacional e internacional.

#### Artículo 5. Informe al Congreso de la República

La Autoridad Nacional expide un informe anual al Congreso de la República acerca de los adelantos en la ejecución de la Política Nacional de Transformación Digital y la Estrategia Nacional de IA.

Si se detectan amenazas graves o violaciones a la ciberseguridad nacional, la Autoridad Nacional notifica de inmediato a la Comisión de Inteligencia del Congreso de la República.

De lo mencionado en la ley, se deduce la trascendencia que en la actualidad se le está proporcionando al uso de la inteligencia artificial a fin de mejorar diferentes servicios en el sector público, entre los cuales se resalta los servicios que se brinda en el sector salud. Por lo tanto, esta ley refuerza el desarrollo de modelos de DL como pruebas de diagnóstico que permita identificar a los pacientes con covid-19 mediante el uso de tomografías computarizadas del tórax en la gestión del covid-19 en el ámbito de la salud.

### **III. METODOLOGÍA**

#### **3.1 Enfoque de la investigación**

El enfoque de la investigación fue del tipo cuantitativo, pues se recolectó información para poder proceder con el análisis estadístico. Asimismo, se buscó ser objetivo y facilita el cotejo entre estudios análogos.

#### **3.2 Métodos de la investigación**

El método de la indagación fue hipotético deductivo, pues en la investigación se parte de una hipótesis central de investigación, la cual fue que el modelo de DL más adecuado a fin que se diagnostique el covid-19 con tomografías computarizadas del tórax es el modelo de RNC GoogLeNet, el cual presenta un valor superior de 95% en el indicador de sensibilidad y un valor del área bajo la curva ROC superior a 0.95. A partir de esta hipótesis se desarrolló la investigación, la cual fue sometida a validación.

#### **3.3 Diseño de la investigación**

El diseño de la investigación fue:

- No experimental, pues no se realizó ninguna intrusión directa sobre los pacientes, no se intervinieron las variables y sólo se limitó a medirlas después de la descarga de la información. Asimismo, fue del tipo retrospectivo, pues la información de los casos con y sin covid-19 fueron fijados con anterioridad sin necesidad de instaurar una relación de causalidad entre la tomografía computarizada del tórax y el diagnóstico de covid-19.
- Transversal, pues se usó la información de las imágenes de las tomografías computarizadas del tórax a un momento dado en un periodo de tiempo.
- Descriptivo, pues la investigación se centró en analizar estadísticamente las imágenes de las tomografías computarizadas del

tórax, haciendo uso de los modelos de DL mediante las arquitecturas de RNC.

- Correlacional, pues buscó encontrar una relación estadística matemática entre las características de las imágenes de las tomografías computarizadas del tórax y el diagnóstico de covid-19.

### **3.4 Población**

La población de la indagación está constituida por 15,235 imágenes de tomografías computarizadas del tórax de pacientes diagnosticados con o sin covid-19 recogidas durante el año 2021, las cuales fueron cuidadosamente etiquetadas por radiólogos expertos para un concurso de Kaggle.

### **3.5 Muestra**

Para el desarrollo de la investigación, se trabajó con el total poblacional; sin embargo, para este tipo de investigaciones, se considera:

- La muestra de entrenamiento para construir el modelo de DL mediante la arquitectura de RNC de AlexNet y GoogLeNet, la cual estuvo conformada por 12,188 imágenes de tomografías computarizadas del tórax, equivalente al 80% del total de las 15,235 imágenes.
- La muestra de validación, que sirvió para contrastar los resultados de los modelos Deep Learning de RNC de AlexNet y GoogLeNet haciendo uso de los indicadores de los valores de sensibilidad y el área bajo la curva ROC, la cual estuvo conformada por 3,047 imágenes de tomografías computarizadas del tórax, equivalente al 20% del total de las 15,235 imágenes.

### **3.6 Operacionalización de la variable de estudio**

Las variables que se van a considerar son:

Y: Identifica si la tomografía computarizada corresponde a un paciente diagnosticado con covid-19 (1: si tiene covid-19 o positivo, 0: no tiene covid-19 o negativo).

X: Es la imagen de la tomografía computarizada del tórax, la cual es representada mediante una matriz de píxeles de 512x512.

### Figura 16

*Imágenes de rayos X de tórax de personas sin covid-19 y con covid-19*

**Negative**



**Positive**



*Nota.* Tomado de *High-Accuracy Covid 19 Prediction from Chest X-Ray Images using Pre-Trained Convolutional Neural Networks in PyTorch*, por B. Sethuraman, 2021, (<https://towardsdatascience.com/high-accuracy-covid-19-prediction-from-chest-x-ray-images-using-pre-trained-convolutional-neural-2ec96484ce0/>).

#### 3.6.1 Definición conceptual

- Paciente con covid-19: indica si el paciente se le ha diagnosticado covid-19.
- Tomografía computarizada del tórax: es la imagen del interior del cuerpo mediante el uso de un ordenador conectada a una máquina de rayos X.

### **3.6.2 Definición operacional**

- Paciente con covid-19: toma el valor de 1 o positivo, si el paciente es diagnosticado con covid-19 y 0 o negativo, si el paciente no ha sido diagnosticado con covid-19.
- Tomografía computarizada: imagen en pixeles de 512x512.

## **3.7 Técnica e instrumento de recolección de datos**

### **3.7.1 Técnica de recolección de datos**

La técnica de recolección de datos fue documental, pues la información es de fuente secundaria, la cual hace referencia a tomografías computarizadas de tórax disponibles en el sitio web de datos abiertos Kaggle. La plataforma de datos de Kaggle fue fundada en el año 2010 y en la actualidad forma parte de Google. Li (2018), hizo el anuncio de la unión de Kaggle con Google Cloud con el fin de acelerar la democratización de la IA. Esta plataforma admite encontrar y publicar base de datos a toda la comunidad de científicos de datos a nivel global.

El procedimiento a fin de la recolección de datos fue mediante la descarga de las imágenes de tomografías computarizadas del tórax alojadas en la plataforma de base de datos abiertas de Kaggle. Se realizó la recolección 15,264 imágenes, posteriormente se realizó una revisión preliminar de las imágenes en cuestiones de calidad y que las etiquetas de diagnóstico sean correctas, teniendo disponibles 15,235 imágenes para el análisis estadístico.

### **3.7.2 Instrumento de recolección de datos**

El instrumento de la investigación para la recolección de las tomografías computarizadas del tórax no es un habitual cuestionario o guía, sino que viene a ser la plataforma Kaggle y la base de datos que permite acceder al conjunto de imágenes de tomografías computarizadas del tórax de pacientes con diagnóstico de covid-19. El conjunto de imágenes en Kaggle se encuentra disponible en la base de datos llamada COVID-19\_X-ray\_Image\_Dataset.

A continuación, se presenta la figura 17, donde se encuentran almacenada la base de datos de imágenes de las tomografías computarizadas del tórax en formato el jpg.

## Figura 17

### Conjunto de imágenes de las tomografías computarizadas del tórax

Compartido conmi... > Covid\_19\_XRay\_Image... > da... > tra...    

Tipo

Nombre 	Propietario	Última modifi...	Tamaño de e	
 .git	 bharath.seth...	20 feb 2021	—	
 14077-43330.jpg 	 bharath.seth...	4 feb 2021	30 kB	
 101547-15720.jpg 	 bharath.seth...	4 feb 2021	22 kB	
 108750-63189.jpg 	 bharath.seth...	4 feb 2021	15 kB	
 116964-1513.jpg 	 bharath.seth...	4 feb 2021	23 kB	
 133232-22877.jpg 	 bharath.seth...	4 feb 2021	21 kB	

## 3.8 Técnicas de análisis de resultados

### 3.8.1 Técnicas de análisis

Se aplicaron las técnicas de análisis estadístico de Deep Learning haciendo uso de una arquitectura de RNC con el objetivo de determinar el modelo más adecuado entre GoogLeNet y AlexNet que diagnóstique el covid-19 empleando las imágenes de tomografías computarizadas del tórax de Kaggle y haciendo uso de los indicadores estadísticos de sensibilidad y el valor del área bajo la curva ROC.

A continuación, se presenta el desarrollo matemático de los modelos de GoogLeNet y AlexNet.

#### a. Modelo DL de RNC GoogLeNet

El modelo de DL de RNC GoogLeNet se fundamenta en la aplicación sucesiva de operaciones matemáticas, la cuales, se describen a continuación:

## 1. Capa Convolutiva

Las capas convolutivas realizan la operación de convolución sobre la entrada utilizando kernels  $W_k$ . La operación matemática básica de convolución para la capa "l" es:

$$Y_{i,j,k}^{(l)} = \sum_{c=1}^C \sum_{m=1}^{F_h} \sum_{n=1}^{F_w} X_{i+m,j+n,c}^{(l-1)} W_{m,n,c,k}^{(l)} + b_k$$

- $X^{(l-1)}$  es la entrada de la capa "l", que proviene de la capa anterior (l-1).
- $W^{(l)}_{m,n,c,k}$  es el valor del filtro en la capa "l" en la posición (m,n,c) para el filtro k.
- $b_k$  es el sesgo asociado al filtro k.

## 2. Aplicación de la función de activación ReLU

Después de cada operación de convolución, el resultado pasa por una función de activación no lineal, como es la función ReLU (Rectified Linear Unit):

$$f(x) = \max(0, x)$$

Esto introduce no linealidad, permitiendo que el modelo aprenda representaciones complejas.

## 3. Aplicación del módulo Inception

La característica más importante de GoogLeNet es el módulo Inception. Este módulo realiza una combinación de diferentes tipos de convoluciones y capas, todo dentro de una sola capa. Los módulos Inception permiten que el modelo capture características de diferentes escalas y provean una arquitectura más eficiente en términos de computación y parámetros. Un módulo Inception típico tiene múltiples ramas que realizan operaciones de convolución con kernels de diferentes tamaños, junto con una operación de pooling.

Un módulo de Inception básico consta de las siguientes operaciones:

- Convolución 1x1: Reduce la dimensionalidad (número de filtros).
- Convolución 3x3: Extrae características locales de la imagen.
- Convolución 5x5: Captura patrones más amplios.

- Max pooling 3x3: Captura la información más significativa dentro de un área local.

La salida del módulo de Inception es la concatenación de los resultados de todas estas operaciones. Matemáticamente, si tenemos  $C_{1x1}$ ,  $C_{3x3}$ ,  $C_{5x5}$ ,  $C_{pool}$  como las salidas de cada una de las operaciones, la salida final del módulo es:

$$Y_{i,j} = \text{concat}(C_{1x1}, C_{3x3}, C_{5x5}, C_{pool})$$

Esto genera un vector de características que captura información de diferentes escalas y tipos de patrones.

#### 4. Capa de Max-Pooling

GoogLeNet utiliza max pooling para reducir la dimensionalidad y mejorar la invariancia espacial. La operación de pooling se define como:

$$P_{i,j} = \max_{m,n \in \text{vecindad}} (X_{i+m,j+n})$$

#### 5. Capa Totalmente Conectada

Las capas totalmente conectadas están al final de la red. Estas capas conectan todas las activaciones previas a una única capa de salida. La salida de una capa completamente conectada se calcula mediante una multiplicación matricial:

$$y = W \cdot x + b$$

donde  $W$  es la matriz de pesos,  $x$  es el vector de activaciones de la capa anterior, y  $b$  es el vector de sesgos.

#### 6. Capa de Salida y Softmax

En el caso de clasificación, la última capa de la red es una capa de salida que tiene un número de neuronas igual al número de clases posibles (por ejemplo, 2 para casos con o sin covid-19). Al final de la red, se usa la función Softmax para convertir las salidas en probabilidades de las clases:

$$P(y = k|X) = \frac{e^{z_k}}{\sum_{i=1}^C e^{z_i}}$$

donde  $z_k$  es la salida de la capa anterior para la clase  $k$ , y  $C$  es el número total de clases.

## 7. Función de Pérdida

La función de pérdida de GoogLeNet, como en otros modelos de clasificación, es la entropía cruzada:

$$L = - \sum_{k=1}^C y_k \log(P(y = k|X))$$

donde  $y_k$  es la etiqueta verdadera y  $P(y=k|X)$  es la probabilidad predicha para la clase  $k$ .

## 8. Optimización

El entrenamiento de GoogLeNet se realiza utilizando retropropagación y un algoritmo de optimización como Stochastic Gradient Descent (SGD) o Adam. El gradiente de la función de pérdida respecto a los pesos se calcula y los pesos se actualizan de acuerdo con la regla:

$$W_{\text{nuevo}} = W_{\text{viejo}} - \eta \frac{\partial L}{\partial W}$$

donde  $\eta$  es la tasa de aprendizaje.

Este conjunto de operaciones permite al modelo de DL con arquitectura de RNC de GoogLeNet aprender de las imágenes de las tomografías computarizadas del tórax, mejorando su capacidad para el diagnóstico de covid-19 (OpenAI, 2024).

### b. Modelo DL de RNC AlexNet

El modelo de DL de RNC AlexNet se fundamenta en la aplicación sucesiva de operaciones matemáticas, la cuales, se describen a continuación:

#### 1. Capa Convolutiva

En AlexNet, se utilizan varias capas convolucionales para extraer representaciones jerárquicas de las imágenes de entrada.

Supongamos que tenemos una imagen de entrada "I" y un kernel "K". La operación de convolución se puede representar como:

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i + m, j + n) \cdot K(m, n)$$

Donde:

- $S(i, j)$  es el mapa de características resultante de la operación de convolución.
- $I(i, j)$  es el valor del píxel en la imagen de entrada.
- $K(m, n)$  es el valor del kernel.
- $i, j$  son los índices espaciales de la imagen.
- $m, n$  son los índices del kernel.

El kernel se desliza sobre la imagen de entrada para extraer características locales como bordes, texturas y patrones. En AlexNet, los kernels de las capas convolucionales son aprendidos durante el proceso de entrenamiento.

## 2. Aplicación de la función de activación ReLU

Después de cada operación de convolución, AlexNet emplea la función de activación ReLU, que introduce no linealidad en la red, permitiendo que esta aprenda representaciones más complejas.

La función ReLU se define como:

$$f(x) = \max(0, x)$$

Esta función convierte todos los valores negativos de las activaciones en cero y conserva los valores positivos.

## 3. Capa de Max-Pooling

Se usa en AlexNet después de las capas convolucionales para reducir la resolución espacial de las características extraídas. El objetivo es reducir el tamaño de las representaciones manteniendo las características más importantes.

En Max Pooling, para una ventana de tamaño  $2 \times 2$ , la operación selecciona el valor máximo dentro de esa ventana. Matemáticamente, si "I" es la imagen de entrada y "P" es la salida de la operación de pooling, se tiene:

$$P(i, j) = \max (I(i + m, j + n)) \quad \text{para } m, n \in \{0, 1\}$$

Donde:

- $P(i, j)$  es el valor de la salida después del pooling.
- La operación selecciona el valor máximo de cada ventana 2x2 en la imagen "I".

Este proceso reduce las dimensiones espaciales (alto y ancho) de la entrada y ayuda a prevenir el sobreajuste, al mismo tiempo que hace que las representaciones sean más robustas.

#### 4. Capa Totalmente Conectada

Una vez que se extraen las características mediante las capas convolucionales y de pooling, las representaciones obtenidas se pasan a través de las capas totalmente conectadas. En estas capas, cada neurona está conectada a todas las neuronas de la capa anterior. Estas capas combinan las características extraídas para tomar la decisión final sobre las clases a las que pertenece la imagen.

Matemáticamente, la activación de una capa totalmente conectada "y" se calcula como:

$$y = W \cdot x + b$$

Donde:

- $W$  es la matriz de pesos de la capa totalmente conectada.
- $x$  es el vector de características extraídas de las capas anteriores (las salidas de las capas convolucionales y de pooling).
- $b$  es el vector de sesgos.
- $y$  es la salida de la capa.

Las salidas de las capas totalmente conectadas se pasan a través de funciones de activación (por ejemplo, ReLU) antes de la última capa de salida.

#### 5. Capa de Salida y Softmax

En el caso de clasificación, la última capa de la red es una capa de salida que tiene un número de neuronas igual al número de clases posibles (por ejemplo, 2

para casos con o sin covid-19). Los valores de salida se transforman en probabilidades utilizando la función Softmax.

La función Softmax convierte las activaciones de la capa de salida en probabilidades, de la siguiente manera:

$$P(y_i) = \frac{e^{z_i}}{\sum_j e^{z_j}}$$

Donde:

- $P(y_i)$  es la probabilidad de que la entrada pertenezca a la clase “i”.
- $z_i$  es la activación de la neurona “i” en la capa de salida.
- La suma en el denominador es sobre todas las clases “j”, normalizando las salidas para que sumen 1.

## 6. Función de Pérdida

La función de pérdida utilizada en AlexNet para problemas de clasificación es la entropía cruzada, la cual mide la discrepancia entre las probabilidades predichas por el modelo y las etiquetas verdaderas.

La función de pérdida se calcula como:

$$L = - \sum_{i=1}^C y_i \log(p_i)$$

Donde:

- $C$  es el número de clases (en este caso, 2: con y sin covid-19).
- $y_i$  es el valor real de la etiqueta (un valor de 0 o 1, dependiendo de la clase).
- $p_i$  es la probabilidad predicha para la clase “i” por la función Softmax.

## 7. Optimización

La optimización en AlexNet se realiza mediante el algoritmo de backpropagation y un algoritmo de optimización, como SGD (Stochastic Gradient Descent) o Adam, para ajustar los pesos  $W$  y los sesgos  $b$ .

El proceso de backpropagation consiste en calcular el gradiente de la función de pérdida con respecto a cada parámetro (peso y sesgo) de la red utilizando la regla de la cadena. Luego, los pesos y sesgos se actualizan para minimizar la pérdida.

La actualización de los pesos se calcula como:

$$W_{\text{nuevo}} = W_{\text{antiguo}} - \eta \cdot \frac{\partial L}{\partial W}$$

Donde:

- $\eta$  es la tasa de aprendizaje.
- $\partial L/\partial W$  es el gradiente de la función de pérdida con respecto a los pesos.

Este conjunto de operaciones permite al modelo de DL con arquitectura de RNC de AlexNet aprender de las imágenes de las tomografías computarizadas del tórax, mejorando su capacidad para el diagnóstico de covid-19 (OpenAI, 2024).

Finalmente, los modelos de DL de RNC GooLeNet y AlexNet, fueron también discutidos en el marco conceptual y con mayor profundidad en los subcapítulos 2.2.9 y 2.2.10. Ambos modelos de Deep Learning fueron entrenados haciendo uso de las imágenes de las tomografías computarizadas del tórax y empleando la librería PyTorch con los programas estadísticos Jupyter Notebook de Anaconda y Google Colab de Google. Para un mayor detalle, se pueden revisar los tutoriales de PyTorch en el anexo 1.

### 3.8.2 Proceso estadístico investigativo

Las actividades del proceso estadístico investigativo que se ven reflejados en los resultados fueron:

- **Primero**, se dividió la base de datos total de las imágenes de las tomografías computarizadas del tórax en una muestra de entrenamiento y una muestra de validación, 80% y 20%, respectivamente.

- **Segundo**, se procedió con la visualización de las imágenes de las tomografías computarizadas del tórax en la muestra de entrenamiento.
- **Tercero**, con la muestra de entrenamiento se construyó el modelo de Deep Learning de Red Neuronal Convolutiva GoogLeNet y se presentó el valor del indicador estadístico de exactitud y error según el número de iteraciones para el entrenamiento del modelo. Luego, con la muestra de validación, se usó la matriz de confusión y se obtuvieron los valores de los indicadores estadísticos de sensibilidad y exactitud. Finalmente, se procedió a calcular el valor del área bajo la curva y presentarla de manera gráfica.
- **Cuarto**, con la muestra de entrenamiento se construyó el modelo de Deep Learning de Red Neuronal Convolutiva AlexNet y se presentó el valor del indicador estadístico de exactitud y error según el número de iteraciones para el entrenamiento del modelo. Luego, con la muestra de validación, se usó la matriz de confusión y se obtuvieron los valores de los indicadores estadísticos de sensibilidad y exactitud. Finalmente, se procedió a calcular el valor del área bajo la curva y presentarla de manera gráfica.
- **Quinto**, con la muestra de validación se procedió a comparar los modelos de DL de Red Neuronal Convolutiva GoogLeNet y AlexNet haciendo uso de los indicadores estadísticos de exactitud, sensibilidad y el valor del área bajo la curva ROC.

## IV. RESULTADOS Y DISCUSIÓN

### 4.1 Muestra de entrenamiento y validación

Antes de iniciar con la construcción de los modelos de GoogLeNet y AlexNet, se procedió a dividir la base de datos de las 15,235 imágenes de las tomografías computarizadas del tórax en una base de datos de entrenamiento de 12,188 imágenes (80%) y una de validación de 3,047 imágenes (20%), siendo esta última la que se usó para la evaluación de los modelos empleando los indicadores de sensibilidad y el área bajo la curva ROC.

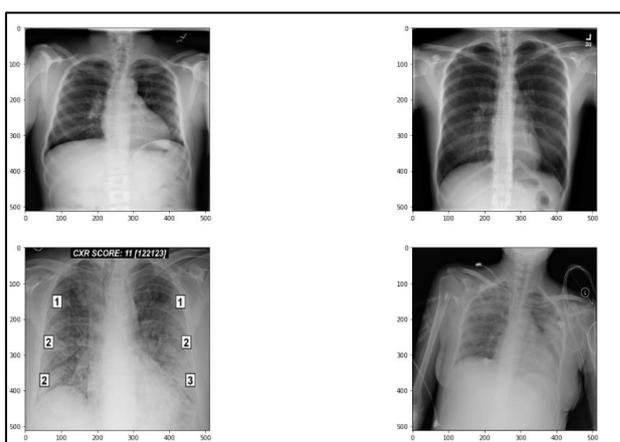
### 4.2 Visualización de las tomografías computarizadas del tórax

Se procedió con la visualización de las imágenes de las tomografías computarizadas del tórax en la muestra de entrenamiento.

Seguidamente, en la figura 18, se visualiza una muestra de las tomografías computarizadas del tórax.

#### Figura 18

*Imágenes de las tomografías computarizadas del tórax en la base de datos de entrenamiento*



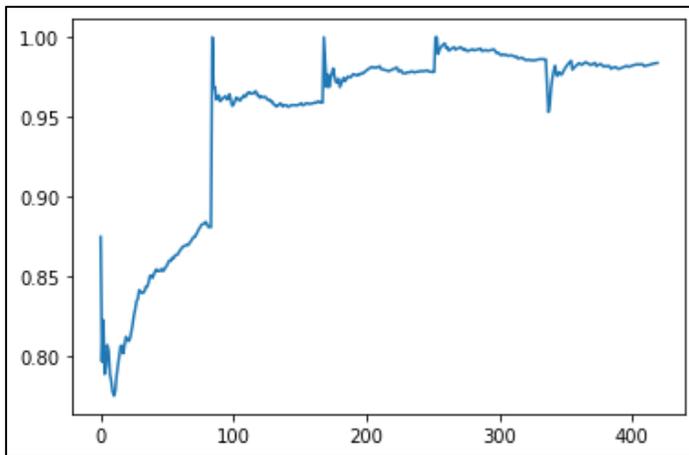
## 4.3 Modelos de Deep Learning

### 4.3.1 Modelo GoogLeNet

Para el entrenamiento del modelo GoogLeNet, en la figura 19, se muestra que el valor del indicador estadístico de exactitud en la muestra de entrenamiento inicia muy bajo y a medida que se acrecienta en número de iteraciones del modelo alcanza a converger a un valor cercano a 1.

#### Figura 19

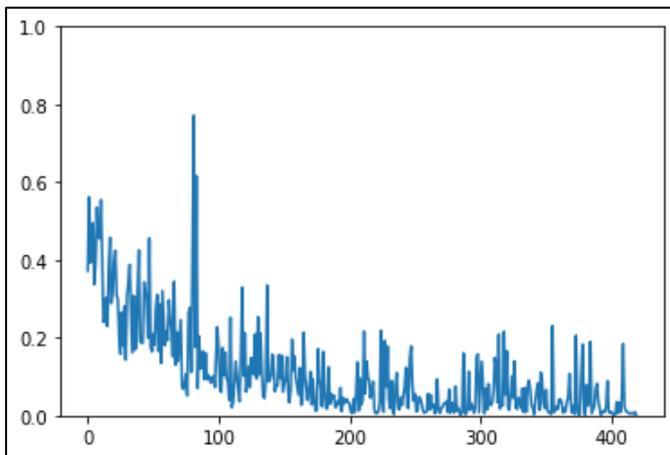
*Valor de la exactitud del modelo de GoogLeNet según las Iteraciones para su entrenamiento*



En la figura 20, se muestra que el valor del indicador de los errores en la muestra de entrenamiento a medida que se acrecienta en número de iteraciones se disminuye hasta que llega a converger a un valor cercano a 0, lo cual muestra que el modelo de GoogLeNet ha tenido un buen aprendizaje de las imágenes que se han ingresado como entrenamiento.

**Figura 20**

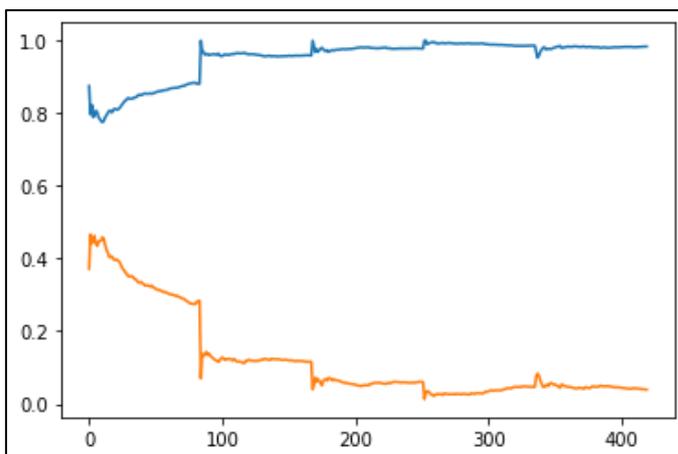
*Errores según las Iteraciones de la muestra de entrenamiento del modelo de GoogLeNet*



En la figura 21, se presenta los indicadores de exactitud y errores del modelo de GoogLeNet, se puede observar que cuando van aumentando las iteraciones, el valor de la exactitud va convergiendo y los errores van disminuyendo. Sin embargo, fue necesario realizar la evaluación del modelo haciendo uso de la muestra de validación y empleando los indicadores de sensibilidad y área bajo la curva ROC.

**Figura 21**

*Exactitud y Errores según las Iteraciones de la muestra de entrenamiento del modelo de GoogLeNet*



Para la evaluación del modelo se usó la muestra de validación. En seguida, se muestra la matriz de confusión en la tabla 2. El valor del indicador estadístico de sensibilidad del modelo de GoogLeNet fue de 99.6%, lo que significa que por cada 100 imágenes de tomografías computarizadas de pacientes con covid-19, el modelo clasificó de manera correcta a 99. Asimismo, se muestra que la exactitud del modelo alcanza un valor del 97%.

**Tabla 2**

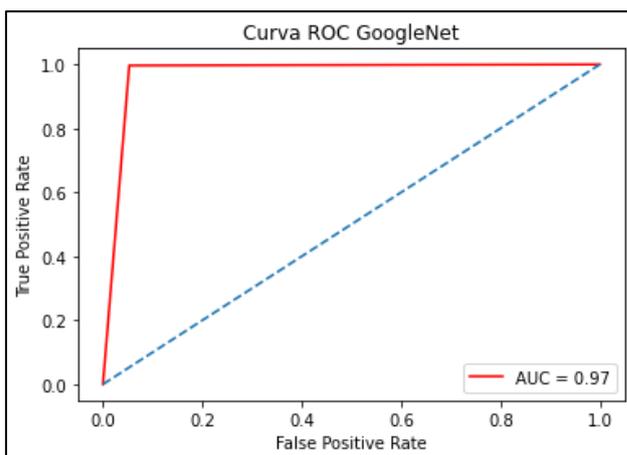
*Matriz de confusión del modelo GoogLeNet*

Observado		Pronosticado		
		Covid-19		Porcentaje correcto
		NO	SI	
Covid-19	NO	1,555	87	94.7%
	SI	5	1,400	99.6%
Porcentaje global				97.0%

Respecto al área bajo la curva ROC, se exhibe en la figura 22, que este alcanza en la muestra de validación un valor de 0.97, encontrándose un test de diagnóstico muy bueno.

**Figura 22**

*Curva ROC del modelo de GoogLeNet*

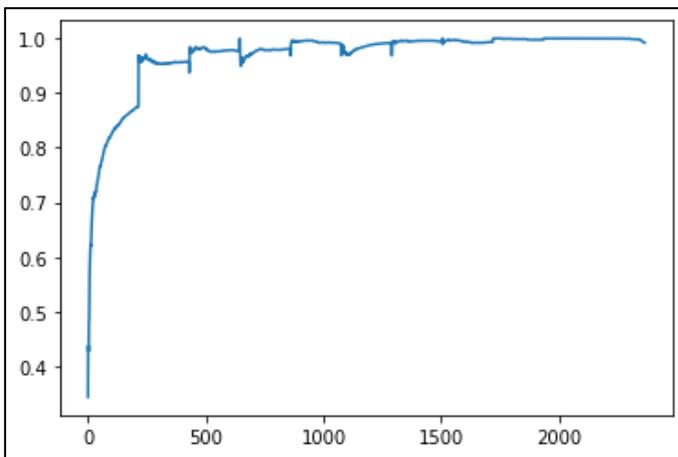


### 4.3.2 Modelo AlexNet

Para el entrenamiento del modelo AlexNet, en la figura 23, se muestra que el valor del indicador estadístico de la exactitud en la muestra de entrenamiento es bajo al inicio de las iteraciones y a medida que se acrecienta en número de iteraciones del modelo alcanza a converger a un valor cercano a 1.

**Figura 23**

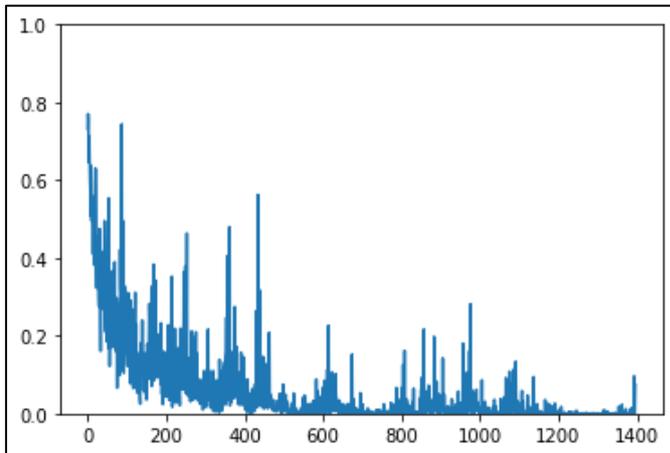
*Valor de la exactitud del modelo de AlexNet según las Iteraciones para su entrenamiento*



En la figura 24, se exhibe que el valor del indicador de los errores en la muestra de entrenamiento a medida que se acrecienta en número de iteraciones se disminuye hasta que llega a converger a un valor cercano a 0, lo cual revela que el modelo de AlexNet ha tenido un buen aprendizaje de las imágenes que se han ingresado como entrenamiento.

**Figura 24**

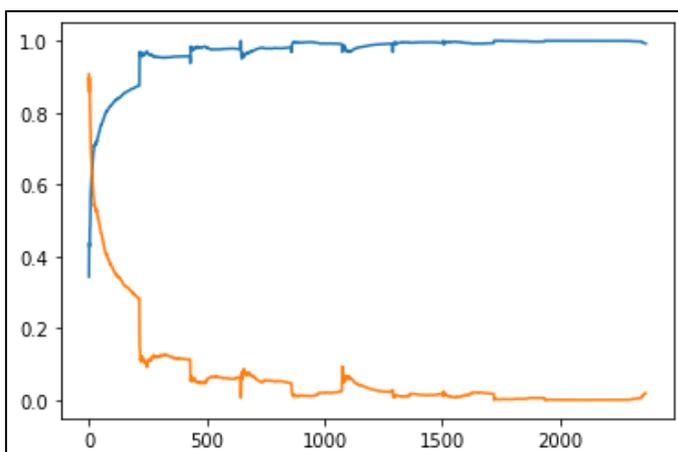
*Errores según las Iteraciones de la muestra de entrenamiento del modelo de AlexNet*



En la figura 25, se presenta los indicadores de exactitud y errores del modelo de AlexNet, se puede observar que cuando van aumentando las iteraciones, el valor de exactitud va convergiendo y los errores van disminuyendo. Sin embargo, fue necesario realizar la evaluación del modelo haciendo uso de la muestra de validación y empleando los indicadores de sensibilidad y área bajo la curva ROC.

**Figura 25**

*Exactitud y Errores según las Iteraciones de la muestra de entrenamiento del modelo de AlexNet*



Para la evaluación del modelo se usó la muestra de validación. Seguidamente, se exhibe la matriz de confusión en la tabla 3. El valor del indicador estadístico

de sensibilidad del modelo de AlexNet fue de 100%, lo que significa que por cada 100 imágenes de tomografías computarizadas de pacientes con covid-19, el modelo clasificó de manera correcta a 100. Asimismo, se muestra que la exactitud del modelo alcanza un valor del 95.9%.

**Tabla 3**

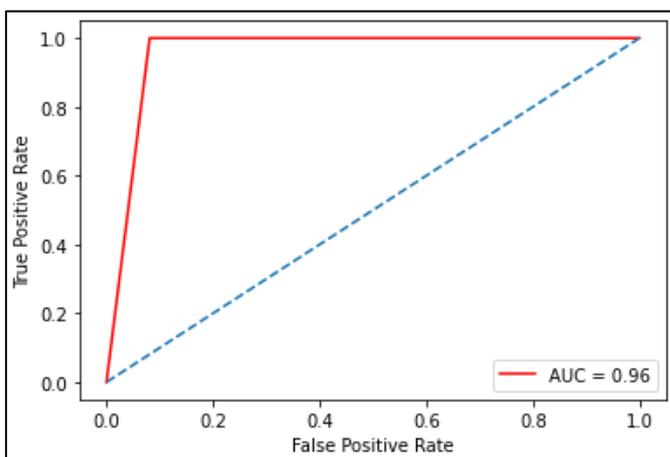
*Matriz de confusión del modelo AlexNet*

Observado		Pronosticado		
		Covid-19		Porcentaje correcto
		NO	SI	
Covid-19	NO	1,429	126	91.9%
	SI	0	1,492	100.0%
Porcentaje global				95.9%

Respecto al área bajo la curva ROC, se exhibe en la figura 26, que este alcanza en la muestra de validación un valor de 0.96, encontrándose un test de diagnóstico muy bueno.

**Figura 26**

*Curva ROC del modelo de AlexNet*



#### 4.4 Comparación de modelos

En la tabla 4, se exteriorizan los indicadores estadísticos de exactitud, sensibilidad y el valor del área bajo la curva ROC hacia los modelos de GoogLeNet y AlexNet.

**Tabla 4**

*Comparación de los modelos de GoogLeNet y AlexNet*

<b>Modelo</b>	<b>Exactitud</b>	<b>Sensibilidad</b>	<b>ROC</b>
GoogLeNet	97.0%	99.6%	0.970
AlexNet	95.9%	100.0%	0.960

En la tabla 4, se aprecia que el modelo de GoogLeNet es el que exhibe mejor ajuste según la exactitud, pues posee un mayor valor que el modelo de AlexNet, 97.0% y 95.9%, respectivamente. Sin embargo, para el diagnóstico de covid-19, el modelo de AlexNet presenta una mayor sensibilidad que el modelo GoogLeNet, 100.0% y 99.6%, respectivamente.

Haciendo la confrontación mediante el uso del área bajo la curva, el modelo de GoogLeNet presenta un área bajo la curva ROC de 0.970 y el modelo de AlexNet un valor de 0.960, por lo tanto, el modelo más conveniente hacia el diagnóstico de covid-19 es el modelo GoogLeNet.

## **V. CONCLUSIONES Y RECOMENDACIONES**

### **5.1 Conclusiones**

En este apartado se expusieron los siguientes hallazgos producto del desarrollo de la actual indagación:

- Se evaluó el desempeño del modelo GoogLeNet para el diagnóstico de covid-19 empleando las imágenes de tomografías computarizadas, presentando un buen desempeño obteniéndose un valor del indicador estadístico de sensibilidad de 99.6% y un valor del área bajo la curva ROC de 0.97.
- Se evaluó el desempeño del modelo AlexNet para el diagnóstico de covid-19 empleando las imágenes de tomografías computarizadas, presentando un buen desempeño obteniéndose un valor del indicador estadístico de sensibilidad de 100% y un valor del área bajo la curva ROC de 0.96.
- Los modelos de GoogLeNet y AlexNet presentaron resultados muy similares para que se diagnostique el covid-19 empleando las imágenes de las tomografías computarizadas con valores de indicadores estadísticos de sensibilidad de 99.6% y 100%, respectivamente. Sin embargo, al emplear el valor del área bajo la curva ROC, el modelo de GoogLeNet presentó un valor de 0.97 y el modelo de AlexNet de 0.96, por consiguiente, estadísticamente el modelo de Deep Learning de RNC GoogLeNet es el más conveniente a fin de diagnosticar el covid-19 con las imágenes de tomografías computarizadas del tórax.

### **5.2 Recomendaciones**

- Se sugiere continuar el estudio, gestionando con las autoridades correspondientes la aplicación de los modelos GoogLeNet y AlexNet en los hospitales y las clínicas más representativas del Perú.

- Para usar una mayor cantidad de imágenes se sugiere adquirir la licencia de una plataforma de big data como Amazon Web Services, Azure de Microsoft o Google Cloud.

## VI. REFERENCIAS BIBLIOGRÁFICAS

- Alake, R. (22 de diciembre de 2020). *Deep Learning: GoogLeNet Explained*. Towards Data Science. Recuperado el 30 de septiembre de 2021 de <https://towardsdatascience.com/deep-learning-googlenet-explained-de8861c82765>
- Akter, S. y Mehedi, F. M. (2021). *COVID-19 Detection using Deep Learning algorithm on Chest X-ray images*. *Biology*.
- Alam, N., Ahsan, M., Based, M., Haider, J. y Kowalski, M. (2021). *COVID-19 Detection from Chest X-ray Images Using Feature Fusion and Deep Learning*. *Sensors*, vol. 21, pp. 1480.
- Aramburu, A., Huaroto, F. y Reyes, N. (2020). *Precisión diagnóstica de pruebas de detección de antígenos para SARS-CoV-2*. Unidad de Análisis y Generación de Evidencias en Salud Pública, Centro Nacional de Salud Pública, Instituto Nacional de Salud.
- Artola, A. (2019). *Clasificación de imágenes usando redes neuronales convolucionales en Python*. Universidad de Sevilla.
- Ayma, D. (03 de enero de 2024). Negativa de población a vacunarse contribuye a aumento de casos de COVID-19, dice decano del Colegio Médico. *Radio Programas del Perú*. <https://rpp.pe/peru/actualidad/negativa-de-poblacion-a-vacunarse-contribuye-al-aumento-de-casos-de-la-covid-19-advierte-decano-del-colegio-medico-noticia-1525301#:~:text=El%20decano%20del%20Colegio%20M%C3%A9dico,casos%20de%20la%20COVID%2D19>
- Bhattacharya, S., Reddy, P., Pham, Q., Reddy, T., Rama, S., Lal, C. y Alazab, M. (2020). *Deep Learning and medical image processing for coronavirus (COVID-19) pandemic: A survey*. Elsevier.

Bocarruido, E. *Detección de COVID-19 en radiografías con Deep Learning*. Instituto de Ingeniería del Conocimiento. Recuperado el 28 de febrero de 2024 de <https://www.iic.uam.es/lasalud/deteccion-covid19-en-radiografias-con-deep-learning/>

Boureau, Y. L., Ponce, J. y LeCun, Y. (2010). *A theoretical analysis of feature pooling in visual recognition*. Proceedings of the ICML.

Centro Nacional de Epidemiología, Prevención y Control de Enfermedades. *Sala Covid-19*. Recuperado el 28 de febrero de 2024 de <https://www.dge.gob.pe/covid19.html>

Chaddad, A., Hassan, L. y Desrosiers, C. (2020). *Deep CNN models for predicting COVID-19 in CT and x-ray images*. Journal of Medical Imaging.

Chollet, F. (2018). *Deep Learning with Python*. Manning.

Coder. (2021). COVID-19 X-ray image classification. Kaggle. <https://kaggle.com/competitions/stat946winter2021>

Diario Médico (16 de diciembre de 2020). *Sólo queda el 10% de 1,400 camas uci operativas en Perú*. Recuperado el 30 de septiembre de 2021 de <https://www.diariomedico.pe/solo-queda-el-10-de-1400-camas-uci-operativas-en-peru/>

Duran, J. y Del Real, A. (2017). *Redes Neuronales Convolucionales*. Universidad de Sevilla.

Fukushima, K. (1980). *Neocognitron: a self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position*. Biological Cybernetics, vol. 36, no. 4, pp. 193–202.

Girshick, R., Donahue, J., Darrell, T. y Malik, J. (2014). *Rich feature hierarchies for accurate object detection and semantic segmentation*. Proceedings of

the 27th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2014, pp. 580–587.

Hadrien, J. (26 de marzo de 2018). *Deep Learning Book Series · 2.1 Scalars Vectors Matrices and Tensors*. Recuperado el 16 de septiembre de 2024 de <https://hadrienj.github.io/posts/Deep-Learning-Book-Series-2.1-Scalars-Vectors-Matrices-and-Tensors/>

Health Big Data. *Redes Neuronales Convolucionales*. Recuperado el 16 de septiembre de 2024 de <https://www.juanbarrios.com/redes-neurales-convolucionales/>

Hinostroza, C. (16 de diciembre de 2020). COVID-19: ¿Cuántas camas UCI disponibles hay a nivel nacional? *Diario Gestión*. <https://gestion.pe/peru/politica/covid-19-cuantas-camas-uci-disponibles-hay-a-nivel-nacional-nczg-noticia/>

Hirsch, L. (febrero de 2022). *Tomografía computada: Tórax (Pecho)*. KidsHealth. Recuperado el 29 de febrero de 2024 de <https://kidshealth.org/es/parents/cat-scan-chest.html#:~:text=%C2%BFQu%C3%A9%20es%20una%20tomograf%C3%ADa%20computada,los%20ganglios%20inf%C3%A1ticos%20del%20paciente>

Hubel, D. H. y Wiesel, T. N. (1962). *Receptive fields, binocular interaction, and functional architecture in the cat's visual cortex*. *The Journal of Physiology*, vol. 160, pp. 106–154.

Inca, C., Paredes, A., Cornejo, P. y Mena, A. (2022). *Eficiencia de modelos de predicción de COVID-19 usando curvas ROC y matriz de confusión*. *Dominio de las Ciencias*, vol. 8, num 2, pp. 1442–1460.

Krizhevsky, A., Sutskever, I. y Hinton, G. (2012). *Image net classification with deep convolutional neural networks*. Proceedings of the 26th Annual Conference on Neural Information Processing Systems, NIPS 2012, pp. 1097–1105.

Krizhevsky, A., Sutskever, I. y Hinton, G. (2014). *ImageNet Classification with Deep Convolutional*. University of Toronto.

LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., y Jackel, L. D. (1989). *Backpropagation applied to handwritten zip code recognition*. Neural Computation, vol. 1, no. 4, pp. 541–551.

LeCun, Y., Bottou, L., Bengio, Y. y Haffner, P. (1998). *Gradient-based learning applied to document recognition*. Proceedings of the IEEE, vol. 86, no. 11, pp. 2278–2323.

Li, F. (08 de marzo de 2017). *Welcome Kaggle to Google Cloud*. Google. Recuperado el 30 de septiembre de 2021 de <https://cloud.google.com/blog/products/gcp/welcome-kaggle-to-google-cloud>

List Data Solutions. *Deep Learning, redes neuronales y visión artificial*. Recuperado el 16 de septiembre de 2024 de <https://www.lisdatasolutions.com/es/blog/deep-learning-redes-neuronales-y-vision-artificial/>

Loanis, D. y Tazani, A. (2020). *Covid-19: detección automática a partir de imágenes de rayos X utilizando aprendizaje de transferencia con redes neuronales convolucionales*. En Phys Eng Sci Med (pp. 635 - 640).

Luengo-Oroz, M. y Hoffmann, K. (2020). *Cooperación de inteligencia artificial para apoyar la respuesta global a COVID-19*.

Minaee, S., Kafieh, R., Sonka, M., Yazdani, S. y Jamalipour, G. (2020). *Deep-COVID: Predicting COVID-19 from chest X-ray images using deep transfer learning*. Elsevier.

OpenAI. (2024). *ChatGPT* (versión GPT-4.0) [Modelo de lenguaje de AI]. Disponible en <https://chat.openai.com/chat>

Oquab, M., Bottou, L., Laptev, I. y Sivic, J. (2015). *Is object localization for free? - Weakly-supervised learning with convolutional neural networks*. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. CVPR, pp. 685–694.

Organización Mundial de la Salud (28 de marzo de 2023). *Información básica sobre la COVID-19*. Recuperado el 28 de febrero de 2024 de <https://www.who.int/es/news-room/q-a-detail/coronavirus-disease-covid-19>

Organización Panamericana de la Salud. *Artículos de opinión de la doctora Carissa F. Etienne*. Recuperado el 28 de febrero de 2024 de <https://www.paho.org/es/directora-emerita-opsoms-dra-carissa-f-etienne/articulos-opinion-doctora-carissa-f-etienne>

Organización Panamericana de la Salud (23 de febrero de 2024). *Preguntas y respuestas: SARS-CoV-2 en América Latina y el Caribe 4 años después*. Recuperado el 28 de febrero de 2024 de <https://www.paho.org/es/noticias/23-2-2024-preguntas-respuestas-sars-cov-2-america-latina-caribe-4-anos-despues>

Pico, J., Muñoz, E. y Analuisa, I. (2022). *Contribución de resnet34 en la detección de covid-19, utilizando radiografías del tórax*, (18), pp.50-68.

RadiologyInfo (01 de noviembre de 2022). *TC del tórax*. Recuperado el 30 de septiembre de 2021 de <https://www.radiologyinfo.org/es/info/chestct>

- Raghav, P. (14 de marzo de 2018). *CNN Architectures — LeNet, AlexNet, VGG, GoogLeNet and ResNet*. Medium. Recuperado el 16 de septiembre de 2024 de <https://medium.com/@RaghavPrabhu/cnn-architectures-lenet-alexnet-vgg-googlenet-and-resnet-7c81c017b848>
- Sarmiento, J. (2020). *Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica*. Revista UIS Ingenierías, vol. 19, núm. 4, pp. 1-18.
- Sethuraman, B. (21 de febrero de 2021). High-Accuracy Covid 19 Prediction from Chest X-Ray Images using Pre-Trained Convolutional Neural Networks in PyTorch. Recuperado el 16 de septiembre de 2024 de <https://towardsdatascience.com/high-accuracy-covid-19-prediction-from-chest-x-ray-images-using-pre-trained-convolutional-neural-2ec96484ce0>
- Soriano, I., Ezponda, A., Mendoza, F., Igual, A., Paternain, A., Pueyo, J. y Bastarrika, G. (2021). *Hallazgos en la tomografía computarizada de tórax en las fases evolutivas de la infección por SARS-Cov-2*. Radiología, vol. 63, no. 3, pp. 218–227.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. y Rabinovich, A. (2015). *Going deeper with convolutions*. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2015, pp. 1–9.
- Trusculescu, A., Manolescu, D., Tudorache, E. y Oancea, C. (2020). *Deep learning in interstitial lung disease—how long until daily practice*. Springer.
- Tygart, M., Bruna, J., Chintala, S., LeCun, Y., Piantino, S. y Szlam, A. (2016). *A mathematical motivation for complex-valued convolutional networks*. Neural Computation, vol. 28, no. 5, pp. 815–825.

Voulodimos, A., Doulamis, N., Doulamis, A. y Protopapadakis, E. (2017). *Deep Learning for Computer Vision: A Brief Review*. Department of Informatics, Technological Educational Institute of Athens.

Wu, J., Wu, X., Zeng, W., Guo, D., Fang, Z., et al. (18 de mayo de 2020). *Hallazgos en TC de tórax en pacientes con la covid19 y su relación con características clínicas*. Asociación Catalana de Técnicos en Imagen para el Diagnóstico. Recuperado el 30 de septiembre de 2021 de <https://www.actedi.cat/es/actualidad/radiographer-journal-club/hallazgos-en-tc-de-torax-en-pacientes-con-la-covid19-y-su-relacion-con-caracteristicas-clinicas-id-59.html>

Yang, D., Martínez, C., Visuña, L., Khandhar, H., Bhatt, C. y Carretero, J. (2021). *Detection and analysis of COVID-19 in medical images using deep learning techniques*. Scientific Reports. Springer Nature.

# ANEXOS

## ANEXO 1

### Tutoriales de PyTorch

<https://pytorch.org/tutorials/>

