



UTMACH

FACULTAD DE INGENIERÍA CIVIL

CARRERA DE TECNOLOGÍAS DE LA INFORMACIÓN

Desarrollo de un aplicativo web utilizando redes neuronales convoluciones para el reconocimiento de enfermedades pulmonares mediante el análisis de radiografías.

**ZHISPON GUZMAN ANTONY RICARDO
INGENIERO EN TECNOLOGIAS DE LA INFORMACION**

**DIAZ PEÑAFIEL JOSE GUILLERMO
INGENIERO EN TECNOLOGIAS DE LA INFORMACION**

**MACHALA
2022**



UTMACH

FACULTAD DE INGENIERÍA CIVIL

CARRERA DE TECNOLOGÍAS DE LA INFORMACIÓN

Desarrollo de un aplicativo web utilizando redes neuronales convolucionales para el reconocimiento de enfermedades pulmonares mediante el análisis de radiografías.

**ZHISPON GUZMAN ANTONY RICARDO
INGENIERO EN TECNOLOGIAS DE LA INFORMACION**

**DIAZ PEÑAFIEL JOSE GUILLERMO
INGENIERO EN TECNOLOGIAS DE LA INFORMACION**

**MACHALA
2022**



UTMACH

FACULTAD DE INGENIERÍA CIVIL

CARRERA DE TECNOLOGÍAS DE LA INFORMACIÓN

PROPUESTAS TECNOLÓGICAS

Desarrollo de un aplicativo web utilizando redes neuronales convolucionales para el reconocimiento de enfermedades pulmonares mediante el análisis de radiografías.

**ZHISPON GUZMAN ANTONY RICARDO
INGENIERO EN TECNOLOGIAS DE LA INFORMACION**

**DIAZ PEÑAFIEL JOSE GUILLERMO
INGENIERO EN TECNOLOGIAS DE LA INFORMACION**

RIVAS ASANZA WILMER BRAULIO

**MACHALA
2022**

zhispondiaz

por Zhispondiaz Zhispondiaz

Fecha de entrega: 12-sep-2022 11:22a.m. (UTC-0500)

Identificador de la entrega: 1898069608

Nombre del archivo: TURNITIN_zhispon-diaz_v2.pdf (1.74M)

Total de palabras: 10906

Total de caracteres: 58175

INFORME DE ORIGINALIDAD

5%

INDICE DE SIMILITUD

5%

FUENTES DE INTERNET

1%

PUBLICACIONES

1%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	repositorio.utmachala.edu.ec Fuente de Internet	1%
2	hdl.handle.net Fuente de Internet	1%
3	cybertesis.unmsm.edu.pe Fuente de Internet	<1%
4	repositorio.utc.edu.ec Fuente de Internet	<1%
5	openaccess.uoc.edu Fuente de Internet	<1%
6	Submitted to Universidad Técnica de Machala Trabajo del estudiante	<1%
7	www.lareferencia.info Fuente de Internet	<1%
8	www.coursehero.com Fuente de Internet	<1%
9	www.mincyt.gob.ar Fuente de Internet	<1%

10 Rigoberto Flores-Mendoza, Josué Uriel Rodríguez-Alcántara, Adrian Pozos-Estrada, Roberto Gómez. "Use of Artificial Neural Networks to predict strong ground motion duration of interplate and inslab mexican Earthquakes for soft and firm soils", Geofísica Internacional, 2022
Publicación <1 %

11 pesquisa.bvsalud.org
Fuente de Internet <1 %

12 doku.pub
Fuente de Internet <1 %

13 es.slideshare.net
Fuente de Internet <1 %

14 prezi.com
Fuente de Internet <1 %

15 www.clubensayos.com
Fuente de Internet <1 %

16 moam.info
Fuente de Internet <1 %

Excluir citas

Activo

Excluir coincidencias < 15 words

Excluir bibliografía

Activo

CLÁUSULA DE CESIÓN DE DERECHO DE PUBLICACIÓN EN EL REPOSITORIO DIGITAL INSTITUCIONAL

Los que suscriben, ZHISPON GUZMAN ANTONY RICARDO y DIAZ PEÑAFIEL JOSE GUILLERMO, en calidad de autores del siguiente trabajo escrito titulado Desarrollo de un aplicativo web utilizando redes neuronales convoluciones para el reconocimiento de enfermedades pulmonares mediante el análisis de radiografías., otorgan a la Universidad Técnica de Machala, de forma gratuita y no exclusiva, los derechos de reproducción, distribución y comunicación pública de la obra, que constituye un trabajo de autoría propia, sobre la cual tienen potestad para otorgar los derechos contenidos en esta licencia.

Los autores declaran que el contenido que se publicará es de carácter académico y se enmarca en las disposiciones definidas por la Universidad Técnica de Machala.

Se autoriza a transformar la obra, únicamente cuando sea necesario, y a realizar las adaptaciones pertinentes para permitir su preservación, distribución y publicación en el Repositorio Digital Institucional de la Universidad Técnica de Machala.

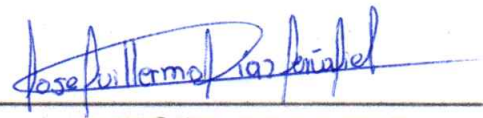
Los autores como garantes de la autoría de la obra y en relación a la misma, declaran que la universidad se encuentra libre de todo tipo de responsabilidad sobre el contenido de la obra y que asumen la responsabilidad frente a cualquier reclamo o demanda por parte de terceros de manera exclusiva.

Aceptando esta licencia, se cede a la Universidad Técnica de Machala el derecho exclusivo de archivar, reproducir, convertir, comunicar y/o distribuir la obra mundialmente en formato electrónico y digital a través de su Repositorio Digital Institucional, siempre y cuando no se lo haga para obtener beneficio económico.




ZHISPON GUZMÁN ANTONY RICARDO

0705642197



DIAZ PEÑAFIEL JOSE GUILLERMO

0705277010



UTMACH

**FACULTAD DE INGENIERÍA CIVIL
CARRERA DE TECNOLOGÍAS DE LA INFORMACIÓN**

**DESARROLLO DE UNA APLICACIÓN WEB PARA EL
RECONOCIMIENTO DE ENFERMEDADES PULMONARES
UTILIZANDO REDES NEURONALES ARTIFICIALES
MEDIANTE EL ANÁLISIS DE RADIOGRAFÍAS**

**ZHISPÓN GUZMÁN ANTONY RICARDO
DÍAZ PEÑAFIEL JOSÉ GUILLERMO**

MACHALA 2022



UTMACH

FACULTAD DE INGENIERÍA CIVIL

CARRERA DE TECNOLOGÍAS DE LA INFORMACIÓN

**DESARROLLO DE UNA APLICACIÓN WEB PARA EL
RECONOCIMIENTO DE ENFERMEDADES PULMONARES
UTILIZANDO REDES NEURONALES ARTIFICIALES
MEDIANTE EL ANÁLISIS DE RADIOGRAFÍAS**

**ZHISPÓN GUZMÁN ANTONY RICARDO
DÍAZ PEÑAFIEL JOSÉ GUILLERMO**

MACHALA 2022



UTMACH

**FACULTAD DE INGENIERÍA CIVIL
CARRERA DE TECNOLOGÍAS DE LA INFORMACIÓN**

**TRABAJO DE INTEGRACIÓN CURRICULAR,
PROPUESTAS TECNOLÓGICAS**

**DESARROLLO DE UNA APLICACIÓN WEB PARA EL
RECONOCIMIENTO DE ENFERMEDADES PULMONARES
UTILIZANDO REDES NEURONALES ARTIFICIALES
MEDIANTE EL ANÁLISIS DE RADIOGRAFÍAS**

**ZHISPÓN GUZMÁN ANTONY RICARDO
DÍAZ PEÑAFIEL JOSÉ GUILLERMO**

RIVAS ASANZA WILMER BRAULIO

MACHALA, 17 DE ENERO DE 2022

MACHALA 2022

DEDICATORIA

El presente trabajo de titulación se lo dedico de manera muy especial a mi familia, que siempre ha sido el pilar fundamental en mi vida, con sus consejos y apoyo incondicional en cada uno de los proyectos a lo largo de mi vida, ya que su motivación me ha permitido superar cada obstáculo académico.

Zhispón Guzmán Antony Ricardo

El presente trabajo se lo dedico a toda mi familia, que gracias a sus consejos y apoyo incondicional se han convertido en una pila fundamental en mi vida, dándome la motivación necesaria para acabar mi carrera universitaria.

Díaz Peñafiel José Guillermo

AGRADECIMIENTO

Agradecemos de manera infinita a nuestras madres quienes desde siempre nos han apoyado y motivado en diferentes aspectos de la vida y especialmente en esta etapa universitaria.

De manera especial quiero agradecer a las siguientes personas:

A nuestro tutor el Ing. Wilmer Rivas y cotutor el Ing. Jhonny Novillo, quienes con sus enseñanzas y constante asesoría hicieron posible que el presente trabajo se desarrolle de manera exitosa.

A la Ing. Bertha Mazón y al Ing. Fausto Redrován por compartir sus conocimientos, por la paciencia, por la dedicación y por habernos guiado paso a paso en el proceso de desarrollo de la tesis.

Zhispón Guzmán Antony Ricardo

Agradezco mucho a toda mi familia que siempre me apoyó en mis decisiones y a pesar de mis fracasos siempre me daban la motivación necesaria para seguir y lograr cumplir mis metas y especialmente en mi etapa universitaria.

De manera especial quiero agradecer a las siguientes personas:

A nuestro tutor el Ing. Wilmer Rivas y cotutor el Ing. Jhonny Novillo, quienes con sus enseñanzas y constante asesoría hicieron posible que el presente trabajo se desarrolle de manera exitosa.

A la Ing. Bertha Mazón y al Ing. Fausto Redrován por compartir sus conocimientos, por la paciencia, por la dedicación y por habernos guiado paso a paso en el proceso de desarrollo de la tesis.

Díaz Peñafiel José Guillermo

RESUMEN

En los últimos años el avance de la IA ha logrado que todos tengamos la capacidad de hacer y entrenar diferentes redes neuronales convolucionales que sean capaces de tomar sus propias decisiones , este proyecto se propone desarrollar un aplicativo web para el reconocimiento de enfermedades pulmonares como COVID-19, Tuberculosis y Neumonía utilizando redes convolucionales por medio del análisis de radiografías con el fin de obtener resultados más eficientes en el menor tiempo posible, ya que hoy en día el tiempo de análisis de radiografías es demasiado extenso al momento de la obtención de resultados.

Para elaborar la red neuronal convolucional se creó una base de datos con un total de 4000 imágenes o radiografías y se las clasificó en cuatro grupos y cada grupo contiene un total de 1000 radiografías: el primer grupo de radiografías de enfermedades es Covid, el segundo grupo de radiografías de enfermedades es Neumonía, el tercer grupo de radiografías de enfermedades es Tuberculosis y el cuarto grupo de radiografías es de Normales.

Para la elaboración de la base de datos de imágenes se utilizó radiografías que fueron obtenidas de la página Kaggle la cual es una plataforma gratuita donde existen un sinnúmero de datasets de cualquier temática, y el resto de radiografías se las recolectó de varias páginas confiables de Internet.

En la actualidad existen diversos métodos de reconocimiento de objetos o enfermedades, para esta tesis las herramientas utilizadas para la elaboración y preparación de la red neuronal fueron Google Colab, la biblioteca Keras y Tensorflow. Posteriormente se procedió a efectuar varias pruebas con la red previamente elaborada y preparada.

Se preparó 2 redes convolucionales con diversos indicadores como el número de épocas que en este caso fueron de 100 y 200, y también el nombre de los optimizadores uno fue el Adam y el otro fue el SGD, con la finalidad de analizar cuál brinda un mejor entrenamiento. Una vez realizado el entrenamiento de la red convolucional se realizó múltiples pruebas dentro del Google Colab, y también se aplicaron varias métricas como por ejemplo la matriz de confusión y de esa manera poder seleccionar la red convolucional más óptima.

Para el uso del modelo creado se desarrolló un aplicativo web para el análisis de las radiografías, y posteriormente poder reconocer el tipo de enfermedad pulmonar. Para el desarrollo de la misma se utilizó Html, CSS, JavaScript, PHP y Python, además se utilizó una base de datos phpMyAdmin donde se guardan los datos de los usuarios. El aplicativo web consta de un login donde los usuarios deberán registrarse para poder hacer uso del mismo, además cuenta con una página que está

dividida en dos secciones: la primera sección nos permite cargar la radiografía en tiempo real y la segunda es la que muestra los resultados en unos progress bar circulares con su respectivo porcentaje de acuerdo a la enfermedad que reconozca.

Y finalmente, se realizaron pruebas en tiempo real con diferentes imágenes de radiografías lo cual nos permitió ver la eficacia de la red convolucional creada.

PALABRAS CLAVE: Clasificación de imágenes, Redes neuronales convolucionales, enfermedades pulmonares, Deep Learning, optimizadores, eficiente, radiografías, Google Colab, TensorFlow, Keras, Kaggle.

ABSTRACT

In recent years, the advancement of AI has achieved that we all have the ability to make and train different convolutional neural networks that are capable of making their own decisions, this project aims to develop a web application for the recognition of lung diseases such as COVID-19, Tuberculosis and Pneumonia using convolutional networks through the analysis of radiographs in order to obtain more efficient results in the shortest possible time, since today the time of analysis of radiographs is too long at the time of obtaining results.

To elaborate the convolutional neural network, a database was created with a total of 4000 images or radiographs and they were classified into four groups and each group contains a total of 1000 radiographs: the first group of disease radiographs is Covid, the second group of X-rays of diseases is Pneumonia, the third group of X-rays of diseases is Tuberculosis and the fourth group of X-rays is Normal.

For the elaboration of the image database, X-rays were obtained from the Kaggle page, which is a free platform where there are countless data sets of any subject, and the rest of the X-rays were collected from several reliable pages. from Internet.

Currently there are various methods of recognizing objects or diseases, for this thesis the tools used for the elaboration and preparation of the neural network were Google Colab, the Keras library and Tensorflow. Subsequently, several tests were carried out with the previously elaborated and prepared network.

Two convolutional networks were prepared with various indicators such as the number of epochs, which in this case were 100 and 200, and also the name of the optimizers, one was Adam and the other was SGD, in order to analyze who provides a better training Once the training of the convolutional network was done, multiple tests were carried out within Google Colab, and various metrics were also applied, such as the confusion matrix, in order to select the most optimal convolutional network.

For the use of the created model, a web application will be developed for the analysis of the radiographs, and later it will be able to recognize the type of lung disease. For its development, Html, CSS, JavaScript, PHP and Python were obtained, as well as a phpMyAdmin database where user data is stored. The web application consists of a login where users must register to be able to use it, it also has a page that is divided into two sections: the first section allows us to load the radiograph in real time and the second is the one that It shows the results in a circular bar progress with its respective percentage according to the disease it recognizes.

And finally, tests were carried out in real time with different X-ray images, which allowed us to see the effectiveness of the convolutional network created.

KEY WORDS: Image classification, Convolutional neural networks, lung diseases, Deep Learning, optimizers, efficient, radiographs, google Colab, TensorFlow, Keras, Kaggle.

ÍNDICE DE CONTENIDO

PORTADA	I
DEDICATORIA.....	IV
AGRADECIMIENTO.....	V
RESUMEN.....	VI
ABSTRACT	VIII
ÍNDICE DE TABLAS	XII
ÍNDICE DE ILUSTRACIONES.....	XIV
GLOSARIO.....	XV
INTRODUCCIÓN	16
Declaración y formulación del Problema	16
Objeto de estudio y Campo de acción	17
Objetivos.....	17
Objetivo General.....	17
Hipótesis y variables o Preguntas de investigación.....	18
Justificación.....	20
1. CAPITULO I. MARCO TEÓRICO.....	21
1.1. Antecedentes de la Investigación.....	21
1.2. Antecedentes Teóricos.....	26
1.2.1. Inteligencia Artificial	26
1.2.2 Machine Learning.....	27
1.2.3 Deep Learning	28
1.2.4 Herramientas	31
1.3. Antecedentes Contextuales.....	32
1.3.1. Ámbito de aplicación	32
1.3.2. Establecimiento de requerimientos	33
2. CAPITULO II. DESARROLLO DEL PROTOTIPO	33
2.1. Definición del prototipo.....	33
2.2. Metodología de desarrollo del prototipo.....	34
2.2.1. Enfoque, alcance y diseño de investigación.....	34
2.2.2. Unidades de análisis.....	35
2.2.3. Técnicas e instrumentos de recopilación de datos	36
2.2.4. Técnicas de procesamiento de datos para la obtención de resultados.....	36

2.2.5.	Metodología o métodos específicos.....	36
2.2.6.	Herramientas y/o Materiales	37
2.3.	Desarrollo del prototipo.....	38
2.4.	Ejecución del prototipo.....	46
3.	CAPITULO III. EVALUACIÓN DEL PROTOTIPO	48
3.1.	Plan de evaluación	48
3.1.1.	Plan de evaluación del modelo.....	48
3.1.2.	Plan de evaluación de la página web	50
3.2.	Resultados de la evaluación.....	50
3.2.1.	Resultados de la Prueba de Entrenamiento	50
3.2.2.	Resultados de la evaluación de la página web	68
4.	CONCLUSIONES	69
5.	RECOMENDACIONES	70
6.	RECOMENDACIONES	71
7.	REFERENCIAS BIBLIOGRÁFICAS	72
8.	ANEXOS.....	75
	Anexo1: Matriz de consistencia.....	75
	Anexo2: Historias de usuario	78
	Anexo3: Código del entrenamiento de la red neuronal convolucional.....	80
	Anexo 4: Código del desarrollo de la página web	82
	Anexo 5: Mobile puntaje	83
	Anexo 6: Servidor de compartimiento.....	84
	Anexo 7: Imágenes	84
	Anexo 8: Links internos	84

ÍNDICE DE TABLAS

Tabla 1: Variables y dimensionamientos	19
Tabla 2: Preguntas de investigación.....	21
Tabla 3: Criterios de inclusión y exclusión.....	22
Tabla 4: Palabras clave de búsqueda y sus citas relacionadas	24
Tabla 5: Técnicas e instrumentos de recopilación de datos	36
Tabla 6: Fases de la metodología XP.....	36
Tabla 7: Fases de la metodología de construcción de redes neuronales convolucionales	37
Tabla 8: Herramientas y Materiales	38
Tabla 9: Definición de roles	39
Tabla 10: Plan de publicaciones.....	40
Tabla 11: Plan de duración de iteraciones.....	41
Tabla 12: Matriz de confusión	49
Tabla 13: Métricas a usar para la evaluación de la página web	50
Tabla 14: Resultados de la prueba de Entrenamiento y Validación.....	50
Tabla 15: Prueba 1 (Optimizador ADAM)	51
Tabla 16: Matriz Consolidada de la enfermedad Covid (Optimizador ADAM).....	52
Tabla 17: Matriz Consolidada de la enfermedad Neumonía (Optimizador ADAM).....	52
Tabla 18: Matriz Consolidada de la enfermedad Tuberculosis (Optimizador ADAM).....	52
Tabla 19: Matriz Consolidada de la enfermedad Normales (Optimizador ADAM).....	53
Tabla 20: Matriz Consolidada de las 4 enfermedades (Optimizador ADAM)	53
Tabla 21: Tabla de evaluación de la precisión (Optimizador ADAM)	53
Tabla 22: Tabla de evaluación de la sensibilidad (Optimizador ADAM).....	54
Tabla 23: Tabla de evaluación del valor de referencia (Optimizador ADAM)	55
Tabla 24: Métricas de evaluación de la prueba 1	55
Tabla 25: Prueba 2 (Optimizador SGD).....	56
Tabla 26: Matriz Consolidada de la enfermedad Covid (Optimizador SGD).....	56
Tabla 27: Matriz Consolidada de la enfermedad Neumonía (Optimizador SGD).....	57
Tabla 28: Matriz Consolidada de la enfermedad Tuberculosis (Optimizador SGD).....	57
Tabla 29: Matriz Consolidada de la enfermedad Normales (Optimizador SGD).....	57
Tabla 30: Matriz Consolidada de las 4 enfermedades (Optimizador SGD).....	58
Tabla 31: Tabla de evaluación de la precisión (Optimizador SGD)	58
Tabla 32: Tabla de evaluación de la sensibilidad (Optimizador SGD).....	59
Tabla 33: Tabla de evaluación del valor de referencia (Optimizador SGD).....	59
Tabla 34: Métricas de evaluación de la prueba 4	60
Tabla 35: Tabulación de resultados de la matriz de confusión de los modelos	61
Tabla 36: Métricas de rendimiento de las cuatro pruebas	62
Tabla 37: Resultados de las pruebas con radiografías reales	64
Tabla 38: Matriz Consolidada de la enfermedad Covid (Optimizador SGD).....	65
Tabla 39: Matriz Consolidada de la enfermedad Neumonía (Optimizador SGD).....	65
Tabla 40: Matriz Consolidada de la enfermedad Tuberculosis (Optimizador SGD).....	65
Tabla 41: Matriz Consolidada de la enfermedad Normales (Optimizador SGD)	66
Tabla 42: Matriz Consolidada de las 4 enfermedades (Optimizador SGD).....	66
Tabla 43: Tabla de evaluación de la precisión (Optimizador SGD)	66
Tabla 44: Tabla de evaluación de la sensibilidad (Optimizador SGD).....	67
Tabla 45: Tabla de evaluación del valor de referencia (Optimizador SGD).....	67

Tabla 46: Evidencia de los resultados de la experiencia dentro del sitio web.	68
Tabla 47: Matriz de consistencia.....	75
Tabla 48: Historia de usuario Nro. 1	78
Tabla 49: Historia de usuario Nro. 2.....	78
Tabla 50: Historia de usuario Nro. 3.....	79
Tabla 51: Historia de usuario Nro. 4.....	79

ÍNDICE DE ILUSTRACIONES

Ilustración 1: Árbol de problema.....	17
Ilustración 2: Diagrama de flujo del proceso de búsqueda SRL	23
Ilustración 3: Cantidad de artículos por años que pasaron los criterios de inclusión.....	24
Ilustración 4: Resultados de la búsqueda por Keywords en la herramienta VOSviewer	25
Ilustración 5: Resultados de documentos por año en el repositorio Scopus.....	25
Ilustración 6: Mapa conceptual del Marco Teórico.....	26
Ilustración 7: Arquitectura de entrenamiento de red neuronal	34
Ilustración 8: Población de Investigación.....	35
Ilustración 9: Fases de la Metodología XP	38
Ilustración 10: Vista de Inicio	41
Ilustración 11: Vista de predicción de las enfermedades	42
Ilustración 12: Fases de la metodología de construcción de redes neuronales convolucionales.....	43
Ilustración 13: Elaboración de la dataset.....	43
Ilustración 14: Flexxi - Renombrar las imágenes.....	44
Ilustración 15: Entrenamiento de la red neuronal.....	44
Ilustración 16: Guardar modelo de la red neuronal	45
Ilustración 17: Ejecución y testeo.....	45
Ilustración 18: Visualización de los resultados de la predicción.....	46
Ilustración 19: Comando para la ejecución del prototipo.....	46
Ilustración 20: Pantalla principal de la página web.....	47
Ilustración 21: Pantalla para la visualización de resultados	47
Ilustración 22: Visualización de la predicción de las enfermedades	48
Ilustración 23: Verdaderos positivos de las tablas	61
Ilustración 24: Verdaderos negativos de las pruebas	62
Ilustración 25: Precisión de las pruebas	63
Ilustración 26: Sensibilidad de las pruebas.....	63
Ilustración 27: Valor de referencia de las pruebas	64
Ilustración 28: Evidencia de los resultados de velocidad del sitio web.....	68

GLOSARIO

CNN: Son uno de los algoritmos de deep learning más populares. Estas han sido adaptadas a diferentes ámbitos profesionales, tales como el de la radiología, logrando el state-of-the-art en el reconocimiento y clasificación de imágenes.

Deep Learning: Es un subconjunto del aprendizaje automático que se caracteriza por la utilización de redes neuronales profundas, es decir, con muchas capas.

IA: Se refiere a la simulación de la inteligencia humana, en máquinas que están programadas para pensar como humanos e imitar sus acciones.

Matriz de Confusión: Es una herramienta que es muy utilizada en el campo de la inteligencia artificial esta permite supervisar el rendimiento de un algoritmo de aprendizaje supervisado.

Optimizador: Esto se usa para la optimización de algoritmos, ayudando a reducir los errores cometidos por la red.

Kaggle: Es una plataforma gratuita que contiene un sinnúmero de problemas para solucionarlos con temas relacionados con la ciencia de datos, aprendizaje automático y análisis predictivo.

Machine Learning: Conocido como aprendizaje automático, tiene como objetivo permitir que los ordenadores aprendan sin ser programadas para alguna tarea en específico.

INTRODUCCIÓN

Durante los últimos años, se ha detectado un aumento significativo de recientes tecnologías que servirán para la creación de diversas herramientas inteligentes que ayuden al área de la salud, un ejemplo puede ser en la detección de enfermedades con la facilidad de subir una imagen.

Por lo tanto, en el presente proyecto se utilizará inteligencia artificial para el entrenamiento de una red neuronal convolucional que permita reconocer enfermedades pulmonares mediante el análisis de radiografías, las cuales fueron obtenidas de la plataforma web Kaggle.

Para el entrenamiento de la red neuronal convolucional se utilizará Google Colab, la cual es una herramienta que permite a cualquier usuario programar código del lenguaje de programación Python, y de esta manera se podrá entrenar la red neuronal utilizando las librerías de Tensorflow y Keras.

Declaración y formulación del Problema

Declaración del problema

Hoy en día las enfermedades pulmonares son unos de los casos de muerte más grandes en el mundo; la OMS manifiesta que la enfermedad que provoca muerte en niños de menos de 5 años es la neumonía y aproximadamente causa 1.4 millones de muerte al año, además esta organización otorga alrededor de 3.9 millones de muertes por enfermedades de infección respiratorias agudas al año.

EPOC se encuentra en el puesto número cuatro de las causas de muerte en el mundo, así que se pronostica que llegará que dentro de algunos años llegará a colocarse como tercera. La incidencia global de esta enfermedad se ha considerado en un 10% de las personas mayores de 40 años. Mucha información manifiesta que la incidencia de esta enfermedad en Latinoamérica procede de dos estudios epidemiológicos: PLATINO y PREPOCOL, los mismos que indican que la incidencia de la EPOC es muy elevada y las ciudades donde frecuentemente se da son: Ciudad de México, São Paulo, Montevideo, Santiago de Chile, Caracas, Barranquilla-Medellín.

Es por eso que las muertes causadas por enfermedades pulmonares son muy altas y esto creció en gran medida cuando apareció el COVID-19 la cual es una de las enfermedades con mayor índice de mortalidad en la actualidad, solo en Ecuador ha sido responsable de 524.432 muertes hasta el momento.

Para los médicos especializados en enfermedades pulmonares cada vez más se les complica obtener resultado más eficiente en el menor tiempo posible, en cuestiones económicas surge la

problemática de que personas con escasos recursos no tienen el dinero suficiente para hacer revisar sus radiografías y esto ocasiona que muchas veces dejen de seguir sus tratamientos médicos.

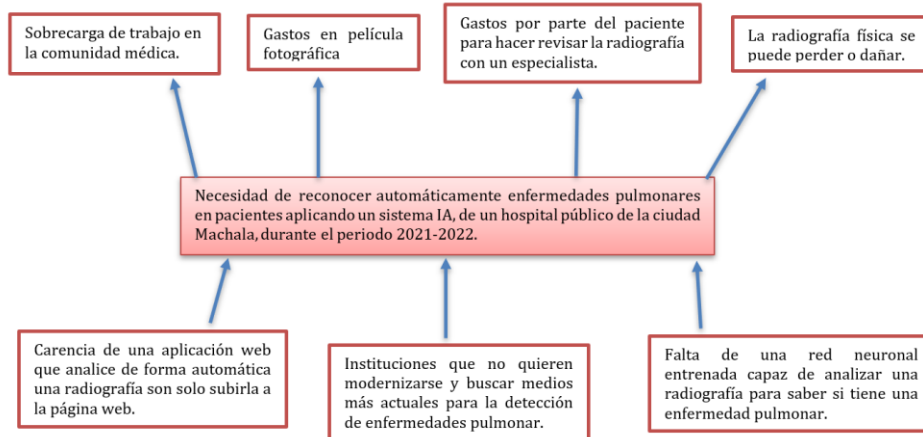


Ilustración 1: Árbol de problema

En la **ilustración 1** anterior se describen las causas y efectos de la problemática planteada dentro del proyecto de investigación, la cual trata de la necesidad de reconocer automáticamente enfermedades pulmonares en pacientes aplicando redes neuronales artificiales, de un hospital público de la ciudad Machala, durante el periodo 2021-2022.

Formulación del problema

- ❖ Necesidad de reconocer automáticamente enfermedades pulmonares en pacientes aplicando redes neuronales artificiales, en un hospital público de la ciudad Machala, durante el periodo 2021-2022.

Objeto de estudio y Campo de acción

Objeto de estudio

- ❖ Reconocimiento de enfermedades pulmonares por medio del análisis de radiografías.

Campo de acción

- ❖ Desarrollo de una Página Web integrando aprendizaje profundo (Deep Learning).

Objetivos

Objetivo General

- ❖ Desarrollar una aplicación web que utilice redes neuronales artificiales mediante el análisis de radiografías para el reconocimiento de enfermedades pulmonares.

Objetivos específicos

- ❖ Realizar una búsqueda bibliográfica de todo lo relacionado con técnicas de deep para obtener un mejor conocimiento del tema.
- ❖ Realizar una búsqueda de la data sobre radiografías de enfermedades pulmonares.
- ❖ Realizar el entrenamiento y procesamiento de las imágenes.
- ❖ Diseñar la aplicación web que analizará la radiografía utilizando una metodología ágil.
- ❖ Realizar pruebas de funcionamiento y depuración.

Hipótesis y variables o Preguntas de investigación

Hipótesis principal (o preguntas de investigación)

- ❖ El desarrollo de una Página Web con operaciones de redes neuronales artificiales para el análisis de radiografías y esto permitirá reconocer automáticamente enfermedades pulmonares en pacientes.

Variables y dimensionamiento (o categorización)

En la siguiente **tabla 1** se muestran las variables independientes y dependientes con sus respectivas categorías, indicadores y técnicas.

Tabla 1: Variables y dimensionamientos

Variables	Categorías	Indicadores	Técnicas
<p>Variable Independiente:</p> <p>Desarrollo de aplicación web con algoritmos de redes neuronales convolucionales</p>	<ol style="list-style-type: none"> 1. Metodologías de desarrollo de aplicación web con IA 2. Deep learning 3. Sistema de detección de imágenes (radiografías) 	<ol style="list-style-type: none"> 1. Comparación de metodologías. 2. Herramientas y lenguaje de programación. 3. Tipos de técnicas para el reconocimiento de imágenes (radiografías). 4. Métricas para evaluar el modelo entrenado. 5. Tipo de metodologías para el desarrollo de páginas web. 	<ol style="list-style-type: none"> 1. Recopilación de información a través de técnicas SRL y la Elaboración de la Dataset. 2. Entrenamiento del modelo utilizando técnicas de Deep Learning, y para la página se usará HTML 5, JavaScript, Html, CSS y php 3. Redes Neuronales Convolucionales 4. Matriz de confusión. <p>Redes neuronales convolucionales</p> <ol style="list-style-type: none"> 5. Metodología XP.
<p>Variable Dependiente:</p> <p>Reconocimiento automático de enfermedades pulmonares en pacientes.</p>	<p>Satisfacción de usuario</p> <p>Eficiencia</p>	<ol style="list-style-type: none"> 1. Visualización de pronósticos al momento del análisis de la radiografía 2. Disponibilidad 	<p>❖ Aprender información a partir de imágenes (radiografías) y Análisis de técnicas de optimización para el aprendizaje de datos.</p>

Justificación

El desarrollo de tecnologías relacionadas con las técnicas de Inteligencia artificial puestas en práctica en el campo de medicina puede disminuir varios aspectos como los costos, el tiempo, los errores médicos entre otros, también pueden incrementar la utilización de los recursos humanos en ramificaciones médicas.

Durante los últimos años la Inteligencia Artificial a empezado a integrarse en el campo de medicina para de aquella manera optimizar los procesos al momento de atender a los clientes y alcanzar una mayor exactitud de los diagnósticos y así poder ofrecer una mejor atención médica. Los registros médicos electrónicos y las radiografías de los pacientes se estiman a través de Deep Learning apoyando en el proceso de análisis o diagnóstico y tratamiento de los pacientes. [7]

Hoy en día los médicos especializados en enfermedades pulmonares se les complica la lucha por reconocerlas, ocasionando que los tiempos para obtener un resultado sean mayores y algunas veces no son 100% correctos, en cuestiones económicas surge la problemática de que personas con escasos recursos no tienen el dinero suficiente para hacer revisar sus radiografías y esto ocasiona que muchas veces dejen de seguir sus tratamientos médicos.

La importancia del siguiente trabajo se enfocará en un estudio profundo sobre la Inteligencia Artificial aplicada en la medicina, es por este motivo que se desarrollará una página web la misma que permitirá el reconocimiento de enfermedades pulmonares por medio del análisis de radiografías utilizando redes neuronales artificiales.

i. Estructura del documento

La estructura del documento es la siguiente:

Capítulo 1: En el presente capítulo se incluyen los antecedentes de la investigación, antecedentes teóricos y los antecedentes contextuales donde se trata del ámbito de aplicación y establecimiento de requerimientos.

Capítulo 2: Se explican definiciones, teoría de la aplicación a desarrollar, objetivos y pruebas de testeo y ejecución.

Capítulo 3: Resultados del proyecto, conclusiones y recomendaciones de acuerdo a los objetivos específicos planteados.

1. CAPITULO I. MARCO TEÓRICO

1.1. Antecedentes de la Investigación

La metodología SRL consta de las actividades: preguntas de investigación, palabras clave y cadena de búsqueda, criterios de inclusión y exclusión y, proceso y resultado de búsqueda. A continuación, se detallan cada una de las actividades antes mencionadas:

a) Preguntas de investigación

En la siguiente **tabla 2** se establecieron las siguientes preguntas para la investigación de datos sobre Redes Neuronales Artificiales y su aplicación en el área de Salud, además de sus herramientas y tecnología existente. La siguiente tabla detalla lo indicado:

Tabla 2: Preguntas de investigación

Pregunta de Investigación	Descripción y motivación
¿Dentro del ámbito tecnológico, que beneficios ha traído la implementación de las Redes Neuronales Artificiales a las organizaciones?	El propósito de esta pregunta es analizar los beneficios que han proporcionado las Redes Neuronales Artificiales e identificar en que otros campos se los podría aplicar.
¿Cuáles son los tipos de redes neuronales artificiales que se pueden implementar para la realización de un sistema de inteligencia artificial (IA)?	El propósito de esta pregunta es identificar los tipos de redes neuronales artificiales, con la finalidad de reconocer cual podría ser más factible usar para obtener un resultado más eficiente.
¿Cuál es el impacto de las redes neuronales artificiales en el área de Salud?	El propósito de esta pregunta es identificar el impacto de las redes neuronales artificiales en el área de salud y saber cuáles han sido los beneficios obtenidos al aplicar esta tecnología.

b) Palabras claves y Cadena(s) de búsqueda

La estrategia de búsqueda incluyó una búsqueda automática, utilizando una cadena validada por expertos en las áreas de redes neuronales artificiales; además de una inclusión manual de artículos bien conocidos sobre requisitos. Las bases de datos digitales seleccionadas y consultadas fueron Science Direct, SpringerLink, Scielo, IEEEXplore.

La cadena de búsqueda se especificó considerando los términos principales bajo investigación (Redes neuronales artificiales, Redes neuronales convolucionales, Inteligencia artificial, enfermedades pulmonares, Inteligencia artificial aplicada en las enfermedades pulmonares).

Realizamos búsquedas piloto para refinar la cadena de búsqueda de forma iterativa. Se excluyeron las palabras clave cuya inclusión no arrojó artículos adicionales en las búsquedas automáticas. Después de varias iteraciones, definimos la siguiente cadena de búsqueda utilizada para buscar en palabras clave, título, resumen y texto completo de las publicaciones:

("redes neuronales convolucionales") AND (covid-19 OR sars-cov-2 OR "Neumonía" OR "Tuberculosis")

Cadena de búsqueda en inglés:

("convolutional neural networks") AND (covid-19 OR sars-cov-2 OR "Pneumonia" OR "Tuberculosis")

c) Criterios de inclusión y exclusión

En la siguiente **tabla 3** se nos indican los criterios de inclusión y exclusión los cuales se utilizarán para la realización del proceso de búsqueda SRL y la elaboración del diagrama de flujo.

Tabla 3: Criterios de inclusión y exclusión

Criterio de inclusión

- 1:** Estudios primarios
- 2:** Estudios que tengan como objetivo la aplicación de redes neuronales en el área de salud
- 3:** Estudios publicados a partir del 2016 hasta la fecha
- 4:** Estudios que relacionan las redes neuronales convolucionales con enfermedades pulmonares

Criterio de exclusión

- 1:** Estudios Secundarios
- 2:** Estudios duplicados
- 3:** Estudios publicados (\leq 2015)
- 4:** Estudios cortos (\leq 3 páginas)
- 5:** Estudios claramente irrelevantes para la investigación
- 6:** Estudios cuyo enfoque no fue la inteligencia artificial aplicada en la Medicina (enfermedades pulmonares)

d) Proceso y resultados de la búsqueda

Diagrama de flujo del proceso de búsqueda SRL.

En la siguiente **tabla 4** se muestra el diagrama de flujo del proceso de búsqueda SRL donde se van a ir filtrando los artículos dependiendo de las normas de inclusión y exclusión mencionadas en la **tabla de criterios y exclusión**.

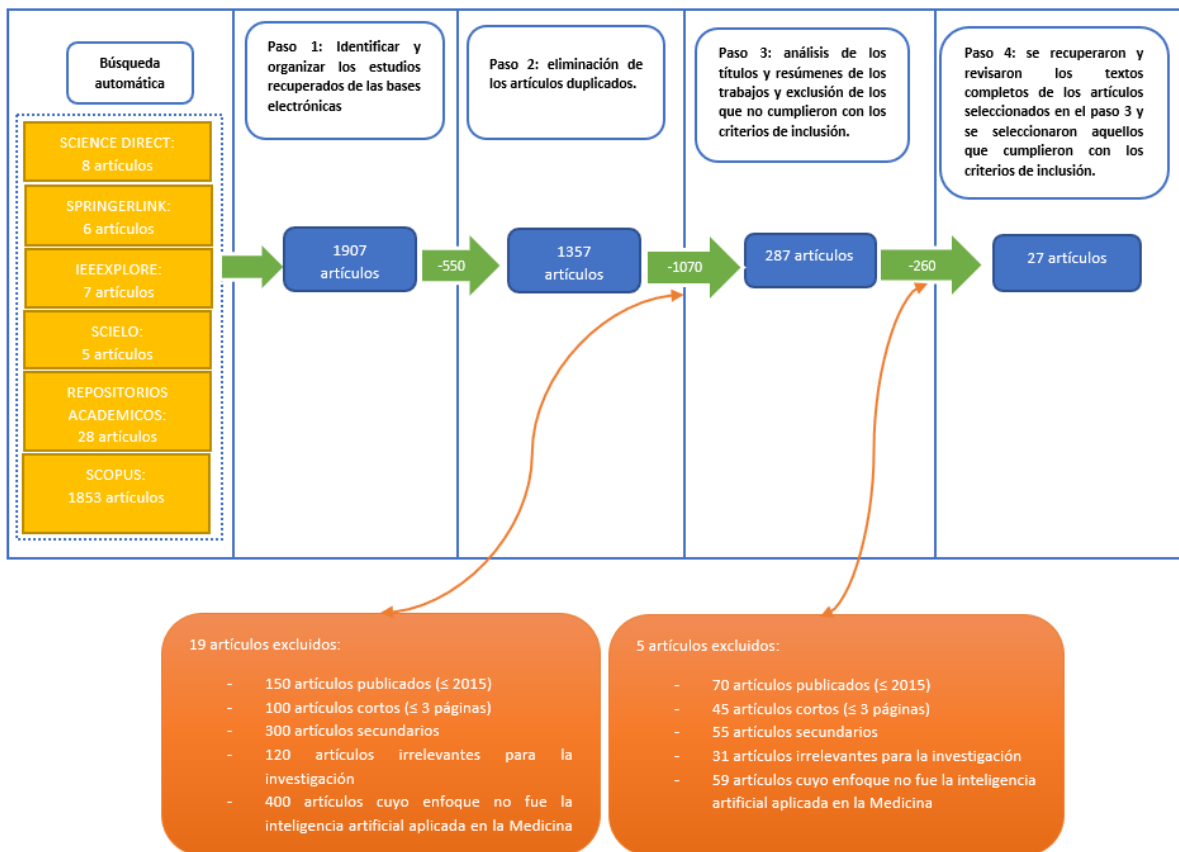


Ilustración 2: Diagrama de flujo del proceso de búsqueda SRL

❖ Cantidad de trabajos por año que pasaron los criterios de inclusión

En la siguiente **ilustración 2** se indica la cantidad de artículos investigados por año para la realización de este anteproyecto, cabe recalcar que solo se contabilizaron los artículos que lograron cumplir con los criterios de inclusión.



Ilustración 3: Cantidad de artículos por años que pasaron los criterios de inclusión

- ❖ Trabajos que abordan o tratan la pregunta de investigación o palabras clave de búsqueda, pueden incluirse también las citas.

En la siguiente **tabla 5** se nos indican las palabras claves que se utilizaron para realizar las búsquedas de los antecedentes teóricos con sus respectivas referencias relacionadas.

Tabla 4: Palabras clave de búsqueda y sus citas relacionadas

TEMAS	REFERENCIAS
Inteligencia artificial	[1] [5] [6] [7] [8] [9] [10] [11] [12]
Machine learning	[6] [10] [13]
Deep learning	[5] [6] [10] [13] [14] [15] [16] [17] [18]
Redes neuronales convolucionales	[19] [20] [21] [22] [23] [24] [25] [26] [27]
Python	[1] [2]
TensorFlow	[1] [2]
Keras	[4]
Dataset	[1]
Big Data	[3]
OpenCV	[2]

A partir de la cadena de búsqueda se obtuvieron los siguientes resultados:

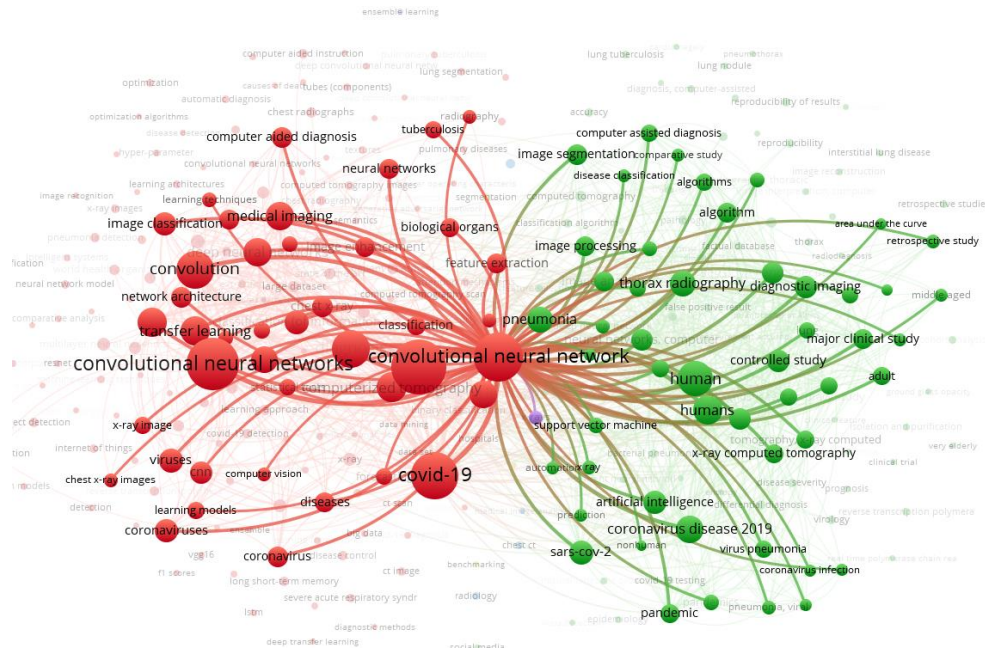


Ilustración 4: Resultados de la búsqueda por Keywords en la herramienta VOSviewer

En la **ilustración 4** se muestran los resultados obtenidos por Keywords en la herramienta VOSviewer, donde se muestran todas las palabras claves relacionadas sobre el reconocimiento de imágenes mediante las redes neuronales convolucionales.

Análisis de los datos de la dataset de Scopus




Ilustración 5: Resultados de documentos por año en el repositorio Scopus

En la **ilustración 5** se visualizan los resultados alcanzados de los documentos por año en el repositorio Scopus, donde se muestran que desde el año 2016 se han realizado documentos relacionados al tema de redes neuronales convolucionales, como se aprecia en la ilustración el año con más documentos realizados es el 2021.

1.2. Antecedentes Teóricos

En la siguiente **ilustración** se indican todos los temas y subtemas de los cuales se van a tratar en el marco teórico y también todas las definiciones relacionadas al tema de investigación.

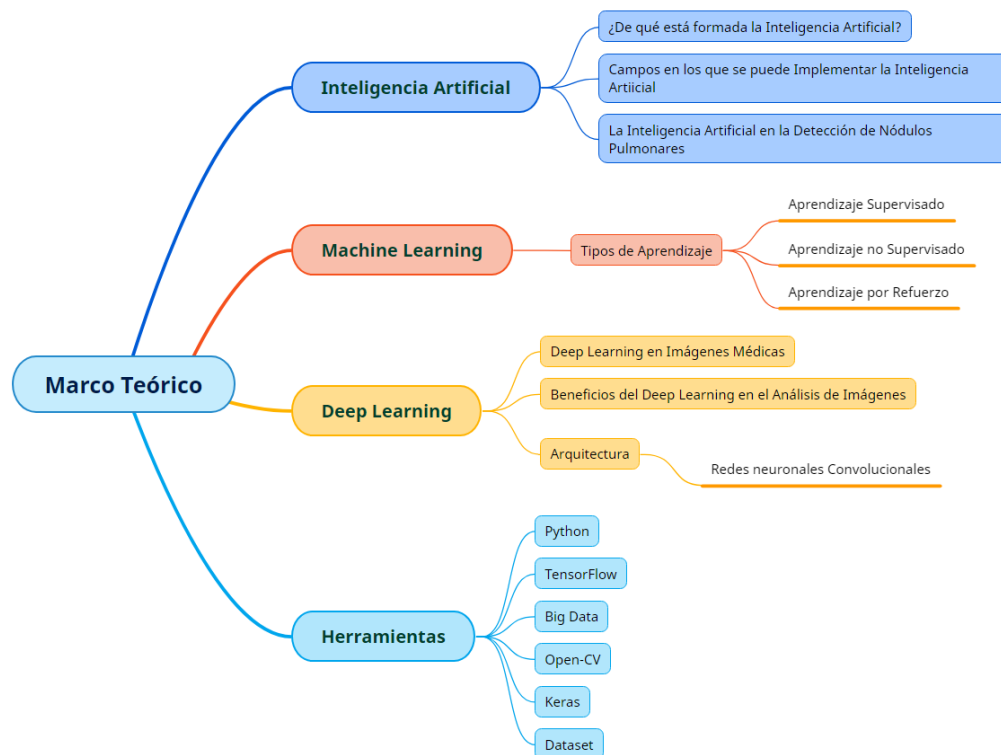


Ilustración 6: Mapa conceptual del Marco Teórico

1.2.1. Inteligencia Artificial

En la informática la IA es el campo científico que ayuda a la innovación de programas y mecanismos que pueden ser llegar a ser considerados autónomos, por lo tanto, la IA hace referencia a la igualdad de la inteligencia humana, en aparatos que están proyectados para especular como individuos e imitar sus operaciones [1, 5, 6].

Tanto es su crecimiento que está pasando rápidamente de una fase experimental a una fase de implementación en muchos campos, incluida la medicina.

¿De qué está formada la Inteligencia Artificial?

La inteligencia artificial está integrada por un sinnúmero de operaciones lógicas completamente formadas mediante las cuales las máquinas son idóneas para la toma de decisiones en cuestiones determinadas desde normas generales, con el propósito de entender y ajustar las capacidades de tratamiento de los datos del instinto humano, y de esta manera alcanzar los elementos generales para exponer y organizar sistemas inteligentes [7, 8, 9].

Campos en los que se puede implementar la Inteligencia Artificial

La IA se puede aplicar en diversos ámbitos los cuales han tenido un gran crecimiento estos últimos años y son [10]:

Reconocimiento, clasificación y etiquetado de imágenes

Implementación de estrategias comerciales

Mejora de la atención médica mediante el procesamiento de datos de pacientes.

Mantenimiento predictivo en el sector industrial.

Asignación de contenido en redes sociales

Herramienta de seguridad cibernética.

La inteligencia Artificial en la Detección de Nódulos Pulmonares

Se han utilizado métodos de aprendizaje profundo de inteligencia artificial (IA) desarrollados recientemente que utilizan redes neuronales convolucionales (CNN) para la detección de nódulos pulmonares, que se ha demostrado que mejoran la sensibilidad de detección y reducen los tiempos de lectura [11].

La inteligencia artificial (IA) en radiología diagnóstica está experimentando un rápido desarrollo. Su utilidad potencial para mejorar el rendimiento diagnóstico de los eventos cardiopulmonares está ampliamente reconocida, pero la exactitud y precisión aún no se han demostrado en el contexto de las modalidades de detección actuales [11, 12].

1.2.2 Machine Learning

Es un modelo de Inteligencia Artificial que otorga a los computadores la destreza de formarse y así mismo efectuar trabajos concretos sin antes haber sido abiertamente programados para aquello [13].

El objetivo fundamental del Machine Learning es la creación de operaciones en virtud de algunos datos de entrada y que estos sean idóneos de pronosticar servicios dentro de una categoría tolerable de exactitud, identificar en los datos (tendencias, patrones) y por último instruirse de la experiencia anterior [10].

También se dice que es una ramificación de la inteligencia artificial establecida en la imagen de que los gobiernos pueden instruirse de los datos, reconocer modelos y captura de ideas con una minúscula intercesión humana [6].

Existen 3 tipos de Machine Learning y son los siguientes:

Tipos de Aprendizaje

Aprendizaje Supervisado

Usa la información previamente etiquetada u organizada, permitiendo que los datos puedan clasificarse de una manera ordenada. Por lo tanto, este tipo de aprendizaje necesita ayuda humana [10].

Aprendizaje NO Supervisado

El aprendizaje no supervisado es una norma que se ajusta a las observaciones. Este se diferencia con el supervisado porque no hay un conocimiento a priorizar [10].

Aprendizaje por Refuerzo

Se basa en dar refuerzos positivos cuando el algoritmo acierta, por lo tanto, consiste en un aprendizaje por “experiencia” [10].

1.2.3 Deep Learning

Una de las nuevas tendencias para la extracción de propiedades mediante el uso del Deep learning, es machine learning la cual es una técnica que se puede usar para el aprendizaje directo de datos [13].

Este término es un subtema del “learning intelligence” este se especifica por el uso de redes neuronales profundas. El funcionamiento de cerebro humano fue la base de inspiración para el funcionamiento del aprendizaje profundo y el diseño fue basado de las redes neuronales humanas. [10].

La inteligencia artificial (IA) es una función del deep learning la cual imita el proceso de datos y la creación de algoritmos que sirven para la toma de decisiones y para esto fue necesario basarse en el funcionamiento del cerebro humano, dando como resultado la creación de redes idóneas de instruirse de forma automática a partir de información no estructurada [6, 14, 5].

Deep Learning en Imágenes Médicas

Entre los algoritmos de aprendizaje, las redes neuronales profundas han dado lugar a avances en el desempeño de tareas, especialmente en el campo de las imágenes médicas. Hasta hace poco, los

sistemas de aprendizaje de reconocimiento de patrones convencionales se componían de dos partes: un extractor de características programado a mano y un algoritmo de aprendizaje automático para clasificar la imagen [15].

Beneficios del Deep Learning en el Análisis de Imágenes

Hoy en día el análisis de imágenes utilizando Deep learning se ha vuelto muy utilizado, ya que ha demostrado ser un enfoque eficaz en detección y segmentación de objetos y clasificación de imágenes, proporcionando una mayor precisión en los resultados que las arquitecturas tradicionales [16, 17], “además, el aprendizaje profundo también ha demostrado su potencial en el análisis de imágenes médicas para la detección y segmentación de objetos, como el análisis de imágenes radiológicas para estudiar estructuras anatómicas o patológicas del cuerpo humano” [16].

Según [18], las redes pre-entrenadas poseen características importantes que las hacen candidatos naturales a la hora de aplicar el aprendizaje profundo a las tareas de clasificación de imágenes médicas: no son costosas, no requieren mucho tiempo de entrenamiento, ni necesitan un gran conjunto de datos para lograr resultados razonablemente buenos.

Por lo tanto, si se usara el Deep learning para crear algún método automatizado capaz de detectar alguna enfermedad esta se podría usar como una herramienta de detección masiva la cual disminuiría muchos los costos de materiales médicos y potencialmente salvando muchas vidas [17, 18].

Arquitectura

El deep learning se basa de una gran cantidad de métodos los cuales emplean arquitecturas neuronales, entre la más importante tenemos las redes neuronales convolucionales las cuales se explican a continuación.

Redes Neuronales Convolucionales

Entre los algoritmos de deep learning más usados tenemos las redes neuronales convolucionales, éstas han sido usadas en muchos campos profesionales, entre el más destacado tenemos la radiología, la cual ha logrado el reconocimiento y clasificación de imágenes automático [19, 20, 21].

Uno de los resultados más prometedores de este tema es en reconocimiento de la neumonía ya que ha logrado una gran capacidad en la clasificación de radiografías, ofreciendo oportunidad de detectar casos de esta enfermedad pulmonar de la manera más eficiente [22, 23].

Las técnicas de deep learning han logrado ofrecer resultados extraordinarios en una amplia gama de tareas de aprendizaje automático, “la CNN es una red neuronal de retroalimentación” [24] y es una de las técnicas que más ha logrado dar resultados exitosos al momento de clasificar imágenes, estas han demostrado ser especialmente eficientes, y se han aplicado con éxito en diversas áreas [18, 26].

Las principales herramientas utilizadas en este ejemplo fueron: Numpy, Pandas, Keras, cuaderno Jupyter, matplotlib y seaborn [25].

Las redes neuronales convolucionales profundas (DCNN)

Es el nombre que se le da a las nuevas estructuras de las redes neuronales y los nuevos cálculos que se utilizan para retomar el uso de estos diseños. El aprendizaje profundo actual proporciona un marco muy poderoso para el aprendizaje supervisado [27].

Arquitectura de las redes neuronales convolucionales

La arquitectura de una CNN cuenta con múltiples capas, las cuales son: Capa convolucional, Capa de acumulación, Capa de aplanamiento, Capa completamente conectada, así como las activaciones ReLU y Softmax [20, 23, 24].

Las redes neuronales convolucionales constan de 4 capas de procesamiento que son:

- ❖ **Capa convolucional:** En esta capa la imagen de entrada se convierte en una forma matricial. Lo siguiente que se aplica es la operación de convolución esta se aplica en la entrada matriz y un detector (filtro, núcleo) de características de dimensión 3x3, dando como resultado un mapa de características [24].
- ❖ **Capa de acumulación:** En esta capa se quiere lograr es muestrear aún más la imagen de entrada, es decir, reducir sus dimensiones. Esto ayuda a reducir el número de parámetros de la imagen, reduciendo así la complejidad computacional [24].
- ❖ **Capa de aplanamiento:** En el aplanamiento, organizamos la función agrupada en un solo vector / columna como entrada para la siguiente capa (convierta nuestros datos 3D a 1D) [2].
- ❖ **Capa completamente conectada:** A esta capa llega la imagen de entrada que paso a través de la capa convolucional y la capa aplanamiento, alimentando a la capa completamente conectada. Luego se procede analizar la imagen calculando sus características dando como resultado una predicción [24].

Funciones de activación

Las funciones de activación que se recomiendan usar son dos y son la ReLU y softmax, pero la que más se usa por la facilidad de entrenar y lograr un mejor rendimiento que otros modelos es la ReLU [24].

ReLU es conocida también como función lineal rectificadora y “es una función lineal que se aplica a la capa convolucional, que consta de mapas de características”. [24]

1.2.4 Herramientas

Big Data

Big Data es un grupo de técnicas computarizadas para examinar grandes cantidades de datos con el propósito de sacar información, modelos, relaciones y entidades importantes para una organización [3].

Hay que recalcar que el Big Data se identifica por poseer 3 calificativos muy importantes que son: “Variedad”, “Velocidad” y “Volumen”, y son conocidos como las 3V.

Python

Es un lenguaje de programación que tolera diferentes paradigmas, ya que soporta diferentes programaciones como orientación a objetos, programación imperativa y programación funcional, además tiene un amplio conjunto de aprendizaje automático predefinido. Esta herramienta tiene diversas funciones de Python integradas que ayudan a la elaboración de sistemas de inteligencia artificial, es versátil, orientada a objetos y tiene un lenguaje de alto nivel [1, 2].

TensorFlow

Se trata de un sistema de machine learning de segunda generación de Google Brain, el mismo que fue salvado como software de código abierto a finales del año 2015 [1].

Esta es una herramienta matemática de código abierto, es usada para hacer cálculos matemáticos usando gráficos de flujo de datos. Esta herramienta es útil para temas relacionados a inteligencia artificial porque ayuda a entrenar y ejecutar redes neuronales profundas para clasificación, reconocimiento y predicción de imágenes [2].

Keras

Esta es una librería de Redes Neuronales de código abierto establecida en Python que incluye la arquitectura de RESNET50, la misma que contribuirá a conseguir las características de las representaciones pictóricas a través de arreglos [4].

Dataset

Es un grupo de información autentica que se utilizan como base para el entrenamiento de algunos algoritmos con el fin de que un computador pueda realizar la toma de decisiones. [1]

Open-CV

Es una biblioteca de procesamiento de imágenes que se utiliza para funcionalidades. Esta es una de las herramientas más usadas para procesar imágenes porque utiliza la biblioteca Numpy, la cual es la más ventajosa para operaciones numéricas ayudando que en nuestros proyectos las imágenes sean transformadas, leídas y mostradas fácilmente [2].

1.3. Antecedentes Contextuales

1.3.1. Ámbito de aplicación

En la contemporaneidad la humanidad está enfrentando un sinnúmero de enfermedades y sobre todo las pulmonares, las más mortales que son Covid-19, neumonía y tuberculosis, las cuales han ocasionado la muerte de varios individuos, las técnicas para reconocer estas enfermedades se han perfeccionado de manera rápida debido al incremento de contagios.

Por consiguiente, se ha planteado el desarrollo de una página web para el reconocimiento de enfermedades pulmonares mediante el análisis de radiografías, con el fin de que los profesionales de la salud tengan a su disposición instrumentos que les permitan realizar un diagnóstico del tipo de enfermedad pulmonar de manera más eficiente.

La inspección de fotografías es una sucesión de un conjunto de procedimientos los mismos que transforman los datos de ingreso en información para ser analizada por un computador. La inspección de fotografías con redes neuronales es muy empleada en trabajos como por ejemplo clasificación de fotografías satelitales y en campos de medicina.

El procedimiento del entrenamiento de una red neuronal debe ser en un lenguaje binario ya que los ordenadores solo entiendes ese lenguaje de 0 y 1, y es en este caso donde se deben aplicar varios algoritmos para que puedan convertir a las imágenes y poder tomar decisiones basándose en el entrenamiento.

Hay diversos instrumentos que ayudan al entrenamiento de las redes neuronales a partir de fotografías. Además, existen algunas aplicaciones para facilitar estos entrenamientos como Google Techable.

El trabajo de titulación tiene como propósito desarrollar una página web que admita el reconocimiento de enfermedades pulmonares mediante el análisis de radiografías, con una dataset de imágenes las mismas que servirán para el entrenamiento de la red neuronal.

1.3.2. Establecimiento de requerimientos

Los pasos que se usaron para la realización de este proyecto investigación curricular son los siguientes:

- ❖ Compilación de fuentes bibliográficas, en este primer paso se realizó una búsqueda de información referente a redes neuronales convolucionales y sobre técnicas de aprendizaje profundo.
- ❖ Creación de la dataset de imágenes para entrenar la red neuronal, para la elaboración de la dataset se usaron un total de 4000 imágenes(radiografías) de buena calidad obtenidas de la plataforma web Kaggle, las cuales están divididas en 4 grupos, 1000 de Covid, 1000 de Neumonía, 1000 de Tuberculosis y 1000 Normales.
- ❖ La estructura de la red neuronal convolucional se la realizó en Google Colab, para el entrenamiento se usó los 4 grupos de imágenes y luego se estableció la cantidad de épocas que se iban a procesar las imágenes dentro de la red neuronal.
- ❖ Desarrollo de la página web, esta será muy intuitiva y amigable con el usuario quien podrá cargar una radiografía para así poder realizar la respectiva predicción.
- ❖ Pruebas, una vez culminada la página web y el entrenamiento de la red neuronal se procedió a realizar las respectivas pruebas de la predicción de las radiografías en tiempo real.

2. CAPITULO II. DESARROLLO DEL PROTOTIPO

2.1. Definición del prototipo

Una de las ventajas de trabajar con CNN es que tienen un mayor porcentaje de eficiente, además de tener la oportunidad de usar imágenes de buena calidad a gran escala. El prototipo de esta propuesta tecnológica se basa en reconocer enfermedades pulmonares mediante del análisis de radiografías, el cual es de gran utilidad ya que agilizará el tiempo de obtención de resultados en

un hospital público. Para el entrenamiento se utilizó una dataset de 4000 imágenes obtenidas de la página web Kaggle.

Luego de que se obtuvo la dataset de imágenes se utilizó Google Colab, el cual permite ejecutar código de Python, siendo este el lenguaje de programación que se usó para entrenar la red neuronal. Las CNN constan de 2 fases: entrenamiento y predicción; la primera empieza cuando se hace la selección de la dataset que se vaya a utilizar, luego estas son subidas al almacenamiento de datos en la nube de nuestra preferencia en nuestro caso utilizamos Google Drive, una vez creada la red neuronal se debe cargar las imágenes guardas de nuestro almacenamiento y comenzar con su optimización.

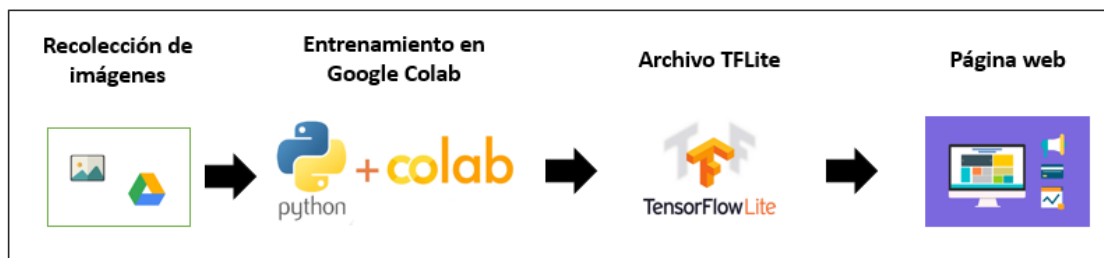


Ilustración 7: Arquitectura de entrenamiento de red neuronal

Cuando se concluyó el entrenamiento, se procedió a descargar el archivo con el respectivo modelo de red neuronal entrenada, el cual se usó para incorporarlo en la página web y así poder cumplir con el objetivo del proyecto que es análisis de imágenes pulmonares de manera automática.

2.2. Metodología de desarrollo del prototipo

2.2.1. Enfoque, alcance y diseño de investigación

Problema de la Investigación: Necesidad de reconocer automáticamente enfermedades pulmonares en pacientes aplicando redes neuronales artificiales, de un hospital público de la ciudad Machala, durante el periodo 2021-2022.

GESTIÓN DEL DISEÑO DE LA INVESTIGACIÓN

El enfoque de investigación

En el ámbito de Tecnologías de la Información TI, el enfoque fue cuantitativo porque se realizó una recolección de datos (imágenes o radiografías) para la construcción de un Dataset que nos permitió entrenar un modelo de red neuronal convolucional, el mismo que sirvió para el reconocimiento de enfermedades pulmonares.

El alcance de investigación

El alcance fue exploratorio y descriptivo, debido que al principio se efectuó una investigación bibliográfica para obtener más información del estudio acerca del tema de Deep Learning aplicado al reconocimiento de imágenes (radiografías) y luego se mostró las especificaciones más importantes encontradas.

El diseño de investigación

El diseño de la investigación fue causi-experimental porque el estudio se realizó en radiografías de enfermedades pulmonares específicas, las cuales se dividieron en grupo intactos de imágenes que sirvieron para pruebas y entrenamiento del algoritmo.

2.2.2. Unidades de análisis

Población

En la siguiente ilustración se nos indica la población de radiografías que se utilizó para la preparación y testeo de la red convolucional, el total fue de 4000 imágenes de éstas se dividieron en tres grupos: Grupo 1(Covid-19), Grupo 2 (Neumonía) y Grupo 3 (Tuberculosis) y cada grupo contará de 1000 imágenes de cuales 850 fueron para el entrenamiento y 150 para pruebas, la fuente de donde se obtuvieron las imágenes de radiografía es de Kaggle [28].

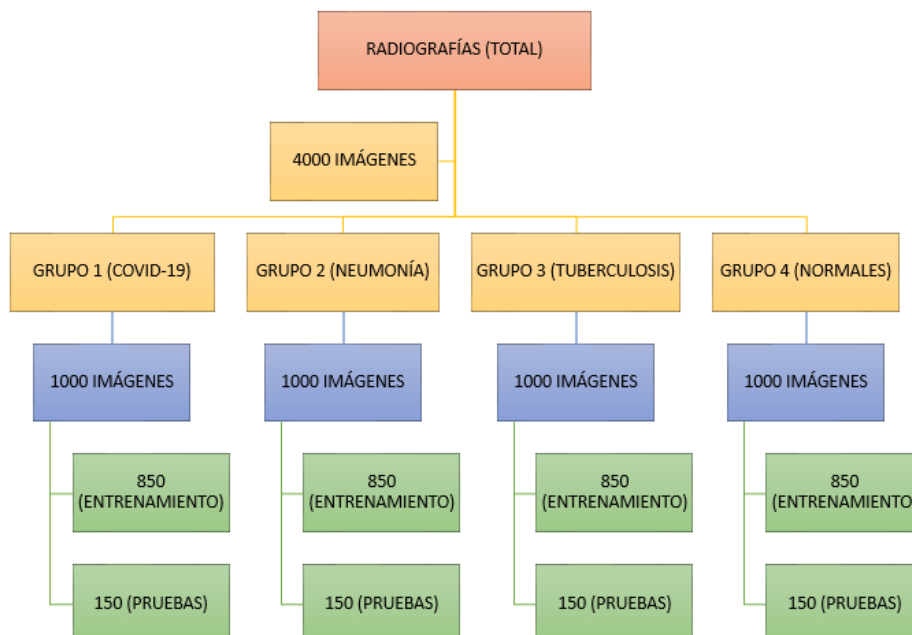


Ilustración 8: Población de Investigación

2.2.3. Técnicas e instrumentos de recopilación de datos

En la siguiente tabla se indican las técnicas que se usaron para realizar la recopilación de datos y que instrumentos se utilizaron.

Tabla 5: Técnicas e instrumentos de recopilación de datos

Técnica	Instrumento
Análisis de documentos o datos	Análisis de documentos relacionados al tema y uso de radiografías.

2.2.4. Técnicas de procesamiento de datos para la obtención de resultados

Se utilizaron las siguientes técnicas de Deep Learning:

- Entrenamiento de la red neuronal convolucional.
- Dataset de imágenes que estén clasificadas por grupos.
- Matriz de confusión.

2.2.5. Metodología o métodos específicos

Metodología para desarrollar la Página Web

La metodología que se utilizó para la elaboración de la Página Web será la Metodología XP porque ayudó a realizar una programación más organizada, se tuvo menos tasa de errores y se adaptó fácilmente a las circunstancias. Esta metodología cuenta con 4 fases las cuales se muestran en la siguiente **tabla**:

Tabla 6: Fases de la metodología XP

FASES DE LA METODOLOGÍA XP			
Planificación	Diseño	Desarrollo o Codificación	Pruebas

Esta metodología es una agrupación de técnicas que proporcionan velocidad y plasticidad en la gestión de proyectos. Se centraliza en establecer un producto según las exigencias exactas del consumidor. El uso de esta metodología supone, para muchos teóricos, una aproximación a la calidad óptima del producto.

Metodología para armar la red neuronal convolucional

La metodología que se usó para armar o entrenar la red convolucional se la conoce como construcción de redes neuronales convolucionales y consta de las siguientes fases y se indican en la **tabla**:

Tabla 7: Fases de la metodología de construcción de redes neuronales convolucionales

FASES DE LA METODOLOGÍA DE CONSTRUCCIÓN DE REDES NEURONALES CONVOLUCIONALES					
Elaboración de la dataset	Desarrollo y entrenamiento de la red neuronal	Ejecución y testeo	Obtención de métricas de cada modelo	Comparación de los modelos	Selección del modelo más óptimo para la detección en tiempo real

A continuación, se describa un poco de cómo se llevará acabo la metodología:

Luego de haber realizado una ardua investigación se identificó que existen varias técnicas para el análisis de radiografías. El propósito es entrenar un modelo usando técnicas de Deep Learning como las CNN.

Lo primero que se realizó es la creación de la dataset de radiografías la cual fue obtenido del portal web Kaggle, luego se les aplicó Deep Learning utilizando herramientas como Tensorflow, Numpy, Keras y Python.

Luego de culminar el entrenamiento del modelo, se realizó pruebas de ejecución con el fin de comparar los modelos entrenados.

Por último, luego de haber comparado los modelos se seleccionó el más eficiente para utilizarlo en el reconocimiento en tiempo real del aplicativo web.

2.2.6. Herramientas y/o Materiales

Algunas de las herramientas y/o materiales que se consideraron usar en el desarrollo de la Página Web para el reconocimiento de enfermedades pulmonares, se detallan en la siguiente tabla:

Tabla 8: Herramientas y Materiales

HERRAMIENTAS	MATERIALES
Softwares	<ul style="list-style-type: none">- Google Colab- Keras- Visual Studio Code- Excel (gráficos estadísticos)- Power Point (mapas conceptuales)- Lucidchart (mapas conceptuales)- Word
Herramientas de Hardware	<ul style="list-style-type: none">- Laptops o Computadora de Mesa
Lenguajes de programación	<ul style="list-style-type: none">- Python- Html- Php- CSS- JavaScript)
Técnica de Deep Learning	<ul style="list-style-type: none">- Redes Neuronales convolucionales
Datos	<ul style="list-style-type: none">- Dataset de imágenes

2.3. Desarrollo del prototipo

Para del desarrollo del prototipado se usarán 2 metodologías: la XP que se va a utilizar para la elaboración de la página web y la construcción de redes neuronales convoluciones que servirá para la creación y entrenamiento del modelo.

Metodología XP:

La metodología XP se empleará para la implementación de la página web y en la ilustración 9 se muestra a detalle las fases de la metodología XP:

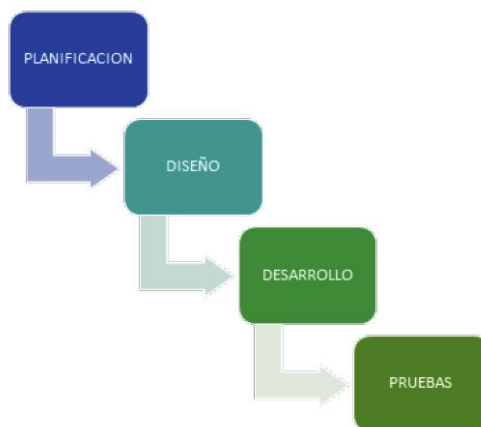


Ilustración 9: Fases de la Metodología XP

FASE I: PLANIFICACIÓN

Definición de roles

Se han establecido los siguientes roles para el desarrollo del proyecto. En la siguiente **tabla** se detallan los roles y responsable.

Tabla 9: Definición de roles

Rol	Responsable
Desarrollador	Ricardo Zhispon, Guillermo Díaz
Encargados del entrenamiento de la red neuronal	Ricardo Zhispon, Guillermo Díaz
Encargados del testeo de la red neuronal	Ricardo Zhispon, Guillermo Díaz
Cliente	Médicos del Hospital de Machala

Historias de usuario

Las historias de usuario que se emplearán para el desarrollo de la página web se encuentran en el anexo A.

Análisis del sistema

➤ Plan de publicaciones

Durante las reuniones de planificación se trató las historias de usuario una a una y definiendo la prioridad para cada una en las 3 iteraciones. Los resultados obtenidos de la reunión de planificación son las historias de usuario que se listan en la siguiente tabla, que incluyen su estimación, tareas en las que se descompone y prioridad.

Esfuerzo i , donde $i=1, 2, 3, n$ semana(s)

Tabla 10: Plan de publicaciones

Nro. H.U.	Nombre H.U.	Prioridad	Esfuerzo	Tareas
1	Crear una cuenta	Alta	2	<ul style="list-style-type: none"> ✓ Interfaz de usuario ✓ Lectura y procesado de la cuenta ✓ Comprobación de resultados
2	Ingresar al sistema web	Alta		<ul style="list-style-type: none"> ✓ Interfaz de usuario ✓ Validación de usuario ✓ Comprobación de resultados
3	Ingresar datos (radiografías)	Alta		<ul style="list-style-type: none"> ✓ Lectura de datos y procesado de la radiografía ✓ Subir fichero con la imagen de la radiografía ✓ Comprobamos resultados en la interfaz de usuario
4	Visualizar los resultados	Baja	1	<ul style="list-style-type: none"> ✓ Lectura de datos y procesado ✓ Comprobación de resultados en la interfaz de usuario mediante la creación de grafico de barras o progress bar.

➤ **Plan de duración de iteraciones**

Se establecen la duración de las iteraciones, acorde a los procesos que se necesiten antes para el desarrollo del proyecto, a pesar de ello, la posibilidad no siempre es favorable ya que es el cliente quien decide qué historias se implementarán en cada iteración.

Tabla 11: Plan de duración de iteraciones

	Iteración 1	Iteración 2	Iteración 3
Historias de usuario	1	2	1
Semanas	2 semanas	3 semanas	4 semanas
Horas semanales	7 h	7 h	7 h
Total de Horas x Semana	14 h	21 h	28 h

FASE II: DISEÑO

Primeramente, se elaboró un prototipado de cómo se visualizaría la página web y para ello se utilizó Balsamiq Mockups.



Ilustración 10: Vista de Inicio

La página principal está conformada por un menú y por un botón que redirige a la página de predicción de las enfermedades.

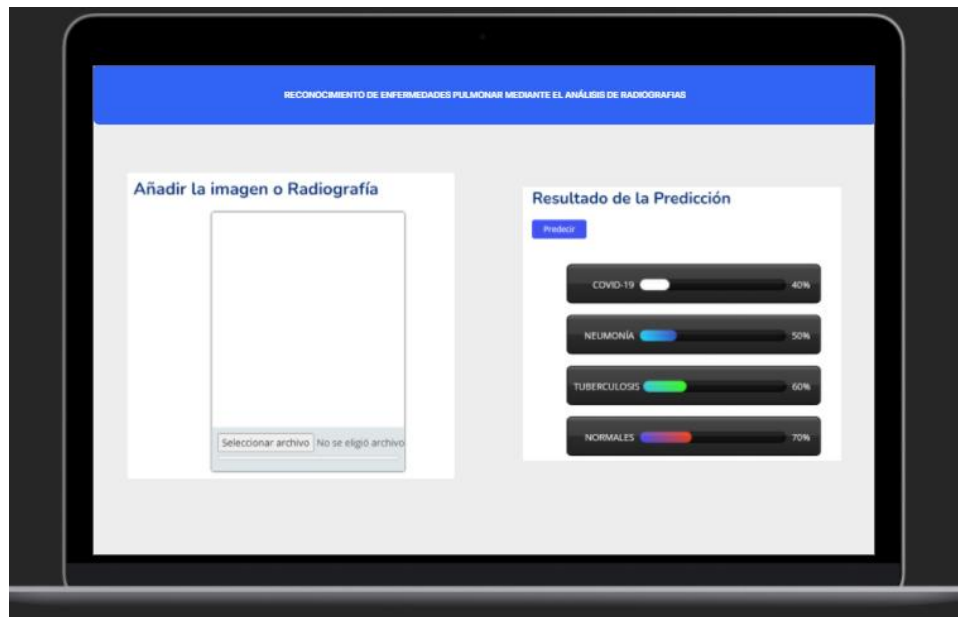


Ilustración 11: Vista de predicción de las enfermedades

La vista de predicción de las enfermedades está formada por varios containers, en uno de ellos se puede cargar la radiografía, en el otro habrá varios progress bar donde se visualizará la predicción de los resultados en base a la radiografía cargada.

FASE III: DESARROLLO

Para el proceso de desarrollo de la red neuronal convolucional se utilizó Google Colab para el entrenamiento de la misma, además se utilizó Python como lenguaje de programación.

Para el proceso de desarrollo de la página web se usó Visual Studio Code como editor de código fuente y JavaScript como lenguajes de programación.

La codificación se la efectuó en dos ramificaciones: una para el entrenamiento de la red neuronal (Ver **Anexo 3**) y otra para el desarrollo de la página web (Ver **Anexo 4**).

Nota: El desarrollo de la **FASE IV** (Pruebas) de la metodología XP se realizará en el siguiente capítulo en la sección de **Resultados de la Evaluación**.

METODOLOGÍA DE CONSTRUCCIÓN DE REDES NEURONALES CONVOLUCIONALES:

La metodología que se usó para armar o entrenar la red neuronal se lo conoce como construcción de redes convolucionales y consta de las siguientes fases.

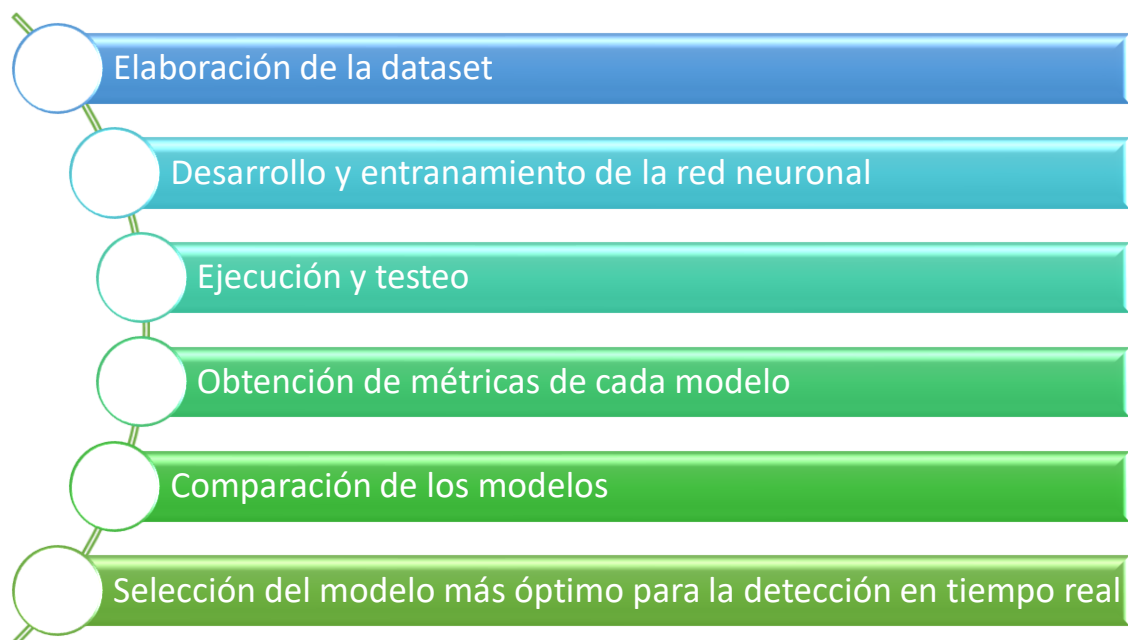


Ilustración 12: Fases de la metodología de construcción de redes neuronales convolucionales

FASE I: ELABORACION DE LA DATASET

Para esta fase se va a elaborar una dataset de enfermedades pulmonares las cuales servirán para el entrenamiento de la red neuronal convolucional, para esto se congregó un total de 4000 radiografías divididas en 4 colecciones 1000 para Covid-19, 1000 para tuberculosis, 1000 para neumonía y 1000 para normales, para cada grupo se dividió 850 para entrenamiento y 150 para testeo.




Ilustración 13: Elaboración de la dataset

Luego de tener la dataset de las radiografías se utilizó la herramienta Flexxi para cambiar el nombre a las imágenes de la siguiente manera: para las imágenes que tienen Covid se las nombro como Covid-train-0001, para las de Neumonía como Neumonía train-0001, para las Normales como Normal-train-0001 y para las de Tuberculosis como Tuberculosis-train-0001.




Ilustración 14: Flexxi - Renombrar las imágenes

FASE II: DESARROLLO Y ENTRENAMIENTO DE LA RED NEURONAL

Para el desarrollo de la red neuronal convolucional se empleó Google Colab.

Entrenamiento_CNN.ipynb ☆

Archivo Editar Ver Insertar Entorno de ejecución Herramientas Ayuda

```

+ Código + Texto

from keras.models import load_model
from keras.preprocessing import image
import numpy as np
import os, cv2
from keras import backend as K
K.set_image_data_format('channels_last')

img_width, img_height = 150, 150 #dimension de las imagenes
num_channel=1

# cargar el modelo
PATH = os.getcwd()
# definicion de ruta
data_path = PATH + '/gdrive/MyDrive/DATASET/model.h5'
print (data_path)
model = load_model(data_path)
print('modelo cargado')

test_image = cv2.imread('/content/gdrive/MyDrive/DATASET/coivd.jpg') #elige la imagen a reconocer
test_image=cv2.cvtColor(test_image, cv2.COLOR_BGR2GRAY) #cambia la imagen de rgb a blanco y negro
test_image=cv2.resize(test_image,(150,150)) #redimensiona la imagen
#test_image = np.array(test_image) #adherir los valores anteriores a un vector
test_image = test_image.astype('float32') #transforma el array en el tamaño float32
test_image /= 255 #redondear
test_image =test_image.reshape(1,150,150)

test_image= np.expand_dims(test_image, axis=3)

print('\tCovid-19\t \tTuberculosis \tNormales \tNeumonia')

```

Ilustración 15: Entrenamiento de la red neuronal

Luego de diseñar la red neuronal se realizó el entrenamiento, para ello se usó el siguiente comando que se muestra en la imagen:

```

Entrenamiento_CNN.ipynb ☆
Archivo Editar Ver Insertar Entorno de ejecución Herramientas Ayuda Se han guardado todos los cambios

+ Código + Texto

[ ] # Guardar el modelo
def guardar_modelo(model):
    # Guardando y cargando el modelo y los pesos
    print('GUARDANDO EL MODELO...')
    model.save('/content/gdrive/MyDrive/DATASET/modelSGD.h5')
    loaded_model=load_model('/content/gdrive/MyDrive/DATASET/modelSGD.h5')
    print('MODELO GUARDADO')

carga_datoset()
clasificacion_imagenes(labels_t, num_clases)
crear_modelo(input_shape)
guardar_modelo(model)

Epoch 73/100
425/425 [=====] - 6s 14ms/step - loss: 0.0611 - accuracy: 0.9750 - val_loss: 0.2667 - val_accuracy: 0.9267
Epoch 74/100
425/425 [=====] - 6s 14ms/step - loss: 0.0677 - accuracy: 0.9718 - val_loss: 0.3097 - val_accuracy: 0.9083
Epoch 75/100
425/425 [=====] - 6s 13ms/step - loss: 0.0590 - accuracy: 0.9762 - val_loss: 0.2589 - val_accuracy: 0.9300
Epoch 76/100
425/425 [=====] - 6s 14ms/step - loss: 0.0526 - accuracy: 0.9797 - val_loss: 0.2473 - val_accuracy: 0.9333
Epoch 77/100
425/425 [=====] - 6s 14ms/step - loss: 0.0611 - accuracy: 0.9768 - val_loss: 0.3102 - val_accuracy: 0.9150
Epoch 78/100
425/425 [=====] - 6s 13ms/step - loss: 0.0634 - accuracy: 0.9759 - val_loss: 0.2908 - val_accuracy: 0.9250
Epoch 79/100
425/425 [=====] - 6s 14ms/step - loss: 0.0437 - accuracy: 0.9826 - val_loss: 0.3032 - val_accuracy: 0.9300
Epoch 80/100
425/425 [=====] - 6s 13ms/step - loss: 0.0540 - accuracy: 0.9785 - val_loss: 0.3404 - val_accuracy: 0.9200
Epoch 81/100
425/425 [=====] - 6s 14ms/step - loss: 0.0446 - accuracy: 0.9800 - val_loss: 0.3136 - val_accuracy: 0.9233
Epoch 82/100
425/425 [=====] - 6s 14ms/step - loss: 0.0525 - accuracy: 0.9818 - val_loss: 0.2651 - val_accuracy: 0.9367
Epoch 83/100
425/425 [=====] - 6s 14ms/step - loss: 0.0442 - accuracy: 0.9829 - val_loss: 0.2994 - val_accuracy: 0.9150

```

Ilustración 16: Guardar modelo de la red neuronal

FASE III: EJECUCIÓN Y TESTEO

Luego de realizar el entrenamiento se procedió a la ejecución y testeo del modelo creado, para eso se usaron los siguientes comandos que ven en la imagen:

```

# Importar librerias
from keras.models import load_model
from keras.preprocessing import image
import numpy as np
import os,cv2
from keras import backend as K
K.set_image_data_format('channels_last')

img_width, img_height = 150, 150 #dimension de las imagenes
num_channel=1
# cargar el modelo
PATH = os.getcwd()
# definicion de ruta
data_path = PATH + '/gdrive/MyDrive/DATASET/model.h5'
print (data_path)
model = load_model(data_path)
print('modelo cargado')

test_image = cv2.imread('/content/gdrive/MyDrive/DATASET/coivid.jpg') #elige la imagen a reconocer
test_image=cv2.cvtColor(test_image, cv2.COLOR_BGR2GRAY) #cambia la imagen de rgb a blanco y negro
test_image=cv2.resize(test_image,(150,150)) #redimensiona la imagen
#test_image = np.array(test_image) #adherir los valores anteriores a un vector
test_image = test_image.astype('float32') #transforma el array en el tamaño float32
test_image /= 255 #redondear
test_image =test_image.reshape(1,150,150)

test_image= np.expand_dims(test_image, axis=3)

print('\tCovid-19\t \tTuberculosis \tNormales \tNeumonia')

```

Ilustración 17: Ejecución y testeo

```
▶ if(predictions.item(0)==1):
    print('Covid')
if(predictions.item(1)==1):
    print('Tuberculosis')
if(predictions.item(2)==1):
    print('Normal')
if(predictions.item(3)==1):
    print('Neumonia')

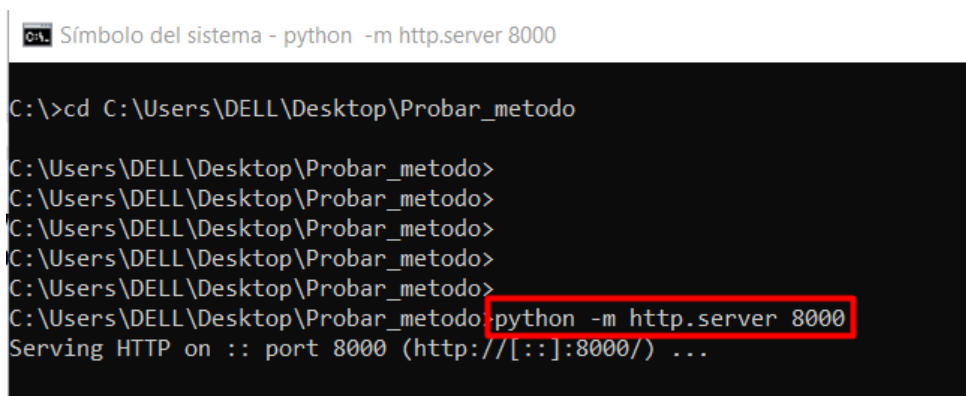
/content/gdrive/MyDrive/DATASET/model.h5
modelo cargado
Covid-19          Tuberculosis    Normales      Neumonia
[[0 0 1 0]]
[[0 0 1 0]]
Normal
```

Ilustración 18: Visualización de los resultados de la predicción

Nota: El desarrollo de la **FASE IV** (obtención de métricas de cada modelo), **FASE V** (comparación de los modelos) y la **FASE VI** (selección del modelo más óptimo para la detección en tiempo real) de la metodología de construcción de redes neuronales convolucionales se realizará en el siguiente capítulo en la sección de **Resultados de la Evaluación**.

2.4. Ejecución del prototipo

Para la ejecución del proyecto se ejecutó principalmente el archivo de la página web desde la terminal con el comando **C:\Users\DELL\Desktop\Probar_metodo>python -m http.server 8000**.



```
C:\> Símbolo del sistema - python -m http.server 8000

C:\>cd C:\Users\DELL\Desktop\Probar_metodo

C:\Users\DELL\Desktop\Probar_metodo>
C:\Users\DELL\Desktop\Probar_metodo>
C:\Users\DELL\Desktop\Probar_metodo>
C:\Users\DELL\Desktop\Probar_metodo>
C:\Users\DELL\Desktop\Probar_metodo>
C:\Users\DELL\Desktop\Probar_metodo>
C:\Users\DELL\Desktop\Probar_metodo>python -m http.server 8000
Servicing HTTP on :: port 8000 (http://[::]:8000/) ...
```

Ilustración 19: Comando para la ejecución del prototipo

Una vez ejecutado el archivo principal de la página web, se procede a abrir el navegador web de su preferencia y se debe escribir la siguiente url <http://localhost:8000/tesis.html> y se cargará de manera inmediata la vista principal del sitio Web.



Ilustración 20: Pantalla principal de la página web

Ahora se debe dar clic en el botón de cargar imagen para que así se pueda visualizar en la pantalla principal los resultados de la enfermedad que tuvo con respecto a la radiografía cargada.




Ilustración 21: Pantalla para la visualización de resultados

Se utilizó una fotografía con Covid y la detección fue exitosa.

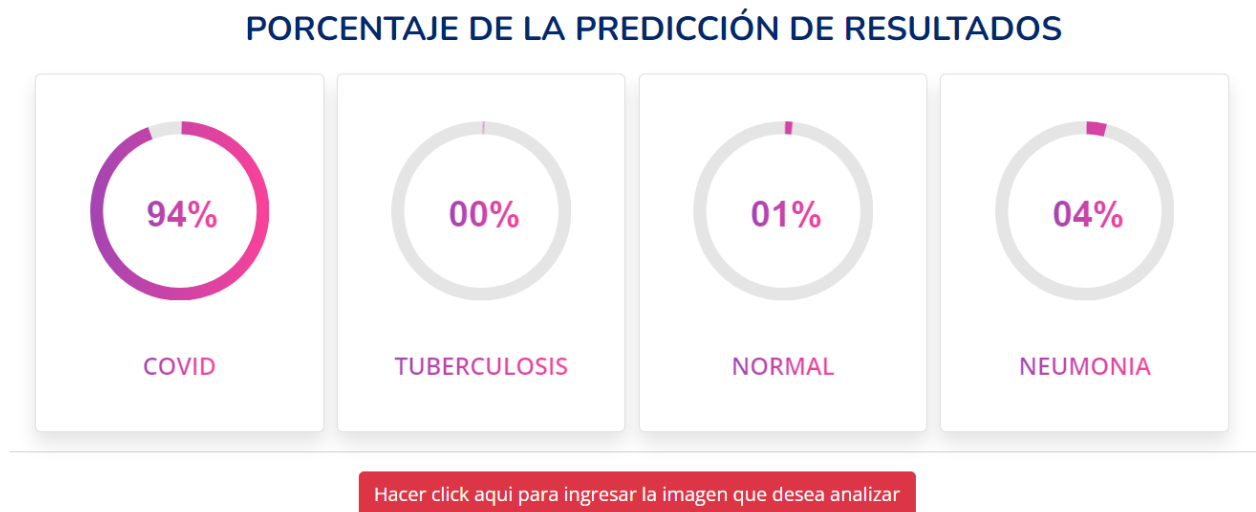


Ilustración 22: Visualización de la predicción de las enfermedades

3. CAPITULO III. EVALUACIÓN DEL PROTOTIPO

3.1. Plan de evaluación

3.1.1. Plan de evaluación del modelo

Para evaluar los resultados se utilizaron diversas métricas tanto de detección como de clasificación para obtener un puntaje y así elegir el modelo más óptimo.

Prueba de Entrenamiento

Métricas

En el campo de la inteligencia artificial y el aprendizaje automático, una matriz de confusión es una herramienta que permite visualizar el desempeño de un algoritmo de aprendizaje supervisado y se puede contrastar la situación real con la predicción del modelo entrenado.

Las salidas que se obtienen al clasificar una red neuronal son de 0 y 1. En la siguiente **tabla 12** se expone la estructura de una matriz de confusión, la misma que esta conformada por Verdaderos Positivos lo que significa que todos los datos analizados son correctos, los Falso Positivo son el número total de datos detectados que no conciernen a los datos entrenados de la red, los Falsos Negativos son el total de datos que la red entrenada no ha reconocido, y por ultimo los Verdaderos Negativos son los datos que tienen similitud al tema y la red lo reconoce como verdadero.

Tabla 12: Matriz de confusión

		Predicción de la red neuronal	
		Objeto presente	Objeto no presente
Situación real	Objeto presente	VP	FN
	Objeto no presente	FP	VN

Las métricas que se utilizarán son las que se muestran a continuación:

Precisión (Precisión)

Nos indica la exactitud que tiene el análisis del elemento seleccionado dándonos como resultados el número de VP que son realmente positivos. Esta métrica se la calcula de la siguiente manera:

$$Precisión = \frac{Verdadero\ Positivo}{Verdadero\ Positivo + Falso\ Positivo}$$

Sensibilidad (Recall)

Muestra los verdaderos positivos totales que la red ha clasificado en base al total de valores positivos. Se la calcula con la siguiente fórmula:

$$Sensibilidad = \frac{Verdadero\ Positivo}{Verdadero\ Positivo + Falso\ Negativo}$$

Valor de Referencia (F-Score)

Esta métrica se considera como una media armónica ya que es la combinación de los valores de precisión y sensibilidad. Para obtener este valor de referencia se aplica la siguiente fórmula:

$$Valor\ de\ Referencia = \frac{Precisión \times Sensibilidad}{Precisión + Sensibilidad}$$

3.1.2. Plan de evaluación de la página web

Como segundo plan de evaluación se van a utilizar dos herramientas web las cuales son Nibbler y Pingdom.

Tabla 13: Métricas a usar para la evaluación de la página web

Herramienta	Concepto
Nibbler	Esta herramienta nos sirve para evaluar la experiencia del usuario usando la página web, además de ser gratuita y dar buenos resultados.
Pingdom	Esta herramienta nos sirve para evaluar la velocidad de respuesta de la página web, esta es una herramienta pagada, pero nos da una prueba gratuita de 30 días.

3.2. Resultados de la evaluación

3.2.1. Resultados de la Prueba de Entrenamiento

Pruebas de entrenamiento

Se realizaron 6 pruebas preliminares, variando los parámetros que permite configurar en el Google Colab (Nombre del optimizador, número de épocas). En la Tabla 14, se detallan las pruebas realizadas; se ha sombreado de color crema la prueba 4 y prueba 6; porque tuvieron un mejor loss y accuracy más de aciertos en la detección de enfermedades

Tabla 14: Resultados de la prueba de Entrenamiento y Validación

Nº pruebas	Optimizador	Épocas	Loss	Accuracy
Prueba 1	Adam	100	0.1776	0.9229
Prueba 2	RMSProp	100	0.3541	0.9076
Prueba 3	Nadam	100	0.0698	0.9785
Prueba 4	Nadam	200	0.0467	0.9841
Prueba 5	SGD	100	0.0497	0.9838
Prueba 6	SGD	200	0.0189	0.9932

Se presenta a continuación las 2 pruebas que muestra mayor cantidad de aciertos en el reconocimiento de enfermedades, con la finalidad de evaluar su rendimiento mediante las métricas de precisión, sensibilidad y valor de referencia.

Nº pruebas	Optimizador	Épocas	Loss	Accuracy
Prueba 1	Nadam	200	0.0467	0.9841
Prueba 2	SGD	200	0.0189	0.9932

Obtención de métricas a partir de la matriz de confusión de cada modelo

Seguidamente, se muestra los resultados del proceso de predicción o testeo de cada uno de las dos pruebas. Para cada modelo se elaboró la matriz de confusión y posteriormente se realizó el cálculo de las métricas correspondientes para cada tipo de emoción.

Prueba 1 (Optimizador Nadam)

MATRIZ DE CONFUSIÓN

En la Tabla 15 se observa los resultados de la predicción comparado con lo real para las 20 imágenes de testeo se destaca que existe una predicción correcta de 18, 15, 13, y 11, para las enfermedades de Covid, Neumonía, Tuberculosis y Normales, a continuación, se muestra el porcentaje de aciertos de todas las enfermedades: 90% de Covid, 75% de Neumonía, 65% de Tuberculosis y 55% de Normales, respectivamente siendo la enfermedad de Covid que tuvo los mejores resultados con un 0.90% de aciertos.

Tabla 15: Prueba 1 (Optimizador ADAM)

		PREDICCIÓN				
		Covid	Neumonía	Tuberculosis	Normales	TOTAL
REAL	Covid	18	0	2	0	20
	Neumonía	4	15	1	0	20
	Tuberculosis	2	4	13	1	20
	Normales	6	2	1	11	20

Matriz de confusión consolidada de la Tabla 14 de la enfermedad Covid

Tabla 16: Matriz Consolidada de la enfermedad Covid (Optimizador ADAM)

		Predicción	
		Enfermedad	No enfermedad
Situación Real	Enfermedad	18	2
	No enfermedad	12	48

Matriz de confusión consolidada de la Tabla 14 de la enfermedad Neumonía

Tabla 17: Matriz Consolidada de la enfermedad Neumonía (Optimizador ADAM)

		Predicción	
		Enfermedad	No enfermedad
Situación Real	Enfermedad	15	5
	No enfermedad	6	54

Matriz de confusión consolidada de la Tabla 14 de la enfermedad Tuberculosis

Tabla 18: Matriz Consolidada de la enfermedad Tuberculosis (Optimizador ADAM)

		Predicción	
		Enfermedad	No enfermedad
Situación Real	Enfermedad	13	7
	No enfermedad	4	56

Matriz de confusión consolidada de la Tabla 14 de la enfermedad Normales

Tabla 19: Matriz Consolidada de la enfermedad Normales (Optimizador ADAM)

		Predicción	
		Enfermedad	No enfermedad
Situación Real	Enfermedad	11	9
	No enfermedad	1	59

Matriz de confusión consolidada de la Tabla 14 de las 4 enfermedades

Tabla 20: Matriz Consolidada de las 4 enfermedades (Optimizador ADAM)

Enfermedades	Verdaderos Positivos	Falsos Positivos	Verdaderos Negativos	Falsos Negativos
	Covid	18	12	2
Neumonía	15	6	5	54
Tuberculosis	13	4	7	56
Normales	11	1	9	59

Métricas de evaluación

Precisión

Tabla 21: Tabla de evaluación de la precisión (Optimizador ADAM)

Enfermedad	Precisión
Covid	0.60
Neumonía	0.71
Tuberculosis	0.76
Normales	0.91

Fórmula

$$Precisión = \frac{Verdadero\ Positivo}{Verdadero\ Positivo + Falso\ Positivo}$$

Resultados

$$\text{Precisión Covid} = \frac{18}{18 + 12} = \frac{18}{30} = 0.60$$

$$\text{Precisión Neumonía} = \frac{15}{15 + 6} = \frac{15}{21} = 0.71$$

$$\text{Precisión Tuberculosis} = \frac{13}{13 + 4} = \frac{13}{17} = 0.76$$

$$\text{Precisión Normales} = \frac{11}{11 + 1} = \frac{11}{12} = 0.91$$

Sensibilidad (Recall)

Tabla 22: Tabla de evaluación de la sensibilidad (Optimizador ADAM)

Enfermedad	Recall
Covid	0.27
Neumonía	0.21
Tuberculosis	0.18
Normales	0.15

Fórmula

$$\text{Sensibilidad} = \frac{\text{Verdadero Positivo}}{\text{Verdadero Positivo} + \text{Falso Negativo}}$$

Resultados

$$\text{Sensibilidad Covid} = \frac{18}{18 + 48} = \frac{18}{66} = 0.27$$

$$\text{Sensibilidad Neumonía} = \frac{15}{15 + 54} = \frac{15}{69} = 0.21$$

$$\text{Sensibilidad Tuberculosis} = \frac{13}{13 + 56} = \frac{13}{69} = 0.18$$

$$\text{Sensibilidad Normales} = \frac{11}{11 + 59} = \frac{11}{70} = 0.15$$

Valor de Referencia

Tabla 23: Tabla de evaluación del valor de referencia (Optimizador ADAM)

Enfermedad	Valor de Referencia
Covid	0.37
Neumonía	0.32
Tuberculosis	0.29
Normales	0.26

Fórmula

$$\text{Valor de Referencia} = 2 \times \frac{\text{Precisión} \times \text{Sensibilidad}}{\text{Precisión} + \text{Sensibilidad}}$$

Resultados

$$V.R. \text{ Covid} = 2 \times \frac{0.60 \times 0.27}{0.60 + 0.27} = 2 \times \frac{0.162}{0.87} = 2 \times 0.1862 = 0.37$$

$$V.R. \text{ Neumonía} = 2 \times \frac{0.71 \times 0.21}{0.71 + 0.21} = 2 \times \frac{0.149}{0.92} = 2 \times 0.1620 = 0.32$$

$$V.R. \text{ Tuberculosis} = 2 \times \frac{0.76 \times 0.18}{0.76 + 0.18} = 2 \times \frac{0.1368}{0.94} = 2 \times 0.1456 = 0.29$$

$$V.R. \text{ Normales} = 2 \times \frac{0.91 \times 0.15}{0.91 + 0.15} = 2 \times \frac{0.1365}{1.06} = 2 \times 0.1288 = 0.26$$

Métricas de evaluación de la prueba 1

Tabla 24: Métricas de evaluación de la prueba 1

Métricas	Covid	Neumonía	Tuberculosis	Normales
Precisión	0.60	0.71	0.76	0.91
Sensibilidad	0.27	0.21	0.18	0.15
Valor de referencia	0.37	0.32	0.29	0.26

En las pruebas realizadas en este modelo se muestra un mejor rendimiento para el reconocimiento

de la enfermedad Normales en la que se obtuvo los siguientes valores: 91% de precisión, 15% de sensibilidad y 26% de valor de referencia.

Prueba 2

MATRIZ DE CONFUSIÓN

En la Tabla 25 se observa los resultados de la predicción comparado con lo real para las 20 imágenes de testeo se destaca que existe una predicción correcta de 18, 15, 14, y 11 para las enfermedades de Covid, Neumonía, Tuberculosis y Normales, a continuación, se muestra el porcentaje de aciertos de todas las enfermedades: 90% de Covid, 75% de Neumonía, 70% de Tuberculosis y 55% de Normales, respectivamente siendo la enfermedad de Covid que tuvo los mejores resultados con un 90% de aciertos.

Tabla 25: Prueba 2 (Optimizador SGD)

		PREDICCIÓN				
		Covid	Neumonía	Tuberculosis	Normales	TOTAL
REAL	Covid	18	0	2	0	20
	Neumonía	4	15	1	0	20
	Tuberculosis	1	4	14	1	20
	Normales	6	2	1	11	20

Matriz de confusión consolidada de la Tabla 25 de la enfermedad Covid

Tabla 26: Matriz Consolidada de la enfermedad Covid (Optimizador SGD)

		Predicción	
		Enfermedad	No enfermedad
Situación Real	Enfermedad	18	2
	No enfermedad	11	49

Matriz de confusión consolidada de la Tabla 25 de la enfermedad Neumonía

Tabla 27: Matriz Consolidada de la enfermedad Neumonía (Optimizador SGD)

		Predicción	
		Enfermedad	No enfermedad
Situación Real	Enfermedad	15	5
	No enfermedad	6	54

Matriz de confusión consolidada de la Tabla 25 de la enfermedad Tuberculosis

Tabla 28: Matriz Consolidada de la enfermedad Tuberculosis (Optimizador SGD)

		Predicción	
		Enfermedad	No enfermedad
Situación Real	Enfermedad	14	6
	No enfermedad	4	56

Matriz de confusión consolidada de la Tabla 25 de la enfermedad Normales

Tabla 29: Matriz Consolidada de la enfermedad Normales (Optimizador SGD)

		Predicción	
		Enfermedad	No enfermedad
Situación Real	Enfermedad	11	9
	No enfermedad	1	59

Matriz de confusión consolidada de la Tabla 25 de las 4 enfermedades

Tabla 30: Matriz Consolidada de las 4 enfermedades (Optimizador SGD)

Enfermedades	Verdaderos Positivos	Falsos Positivos	Verdaderos Negativos	Falsos Negativos
Covid	18	11	2	49
Neumonía	15	6	5	54
Tuberculosis	14	4	6	56
Normales	11	1	9	59

Métricas de evaluación

Precisión

Tabla 31: Tabla de evaluación de la precisión (Optimizador SGD)

Enfermedad	Precisión
Covid	0.62
Neumonía	0.71
Tuberculosis	0.77
Normales	0.91

Fórmula

$$\text{Precisión} = \frac{\text{Verdadero Positivo}}{\text{Verdadero Positivo} + \text{Falso Positivo}}$$

Resultados

$$\text{Precisión Covid} = \frac{18}{18 + 11} = \frac{18}{29} = 0.62$$

$$\text{Precisión Neumonía} = \frac{15}{15 + 6} = \frac{15}{21} = 0.71$$

$$\text{Precisión Tuberculosis} = \frac{14}{14 + 4} = \frac{14}{18} = 0.77$$

$$\text{Precisión Normales} = \frac{11}{11 + 1} = \frac{11}{12} = 0.91$$

Sensibilidad (Recall)

Tabla 32: Tabla de evaluación de la sensibilidad (Optimizador SGD)

Enfermedad	Recall
Covid	0.27
Neumonía	0.21
Tuberculosis	0.20
Normales	0.15

Fórmula

$$\text{Sensibilidad} = \frac{\text{Verdadero Positivo}}{\text{Verdadero Positivo} + \text{Falso Negativo}}$$

Resultados

$$\text{Sensibilidad Covid} = \frac{18}{18 + 49} = \frac{18}{67} = 0.27$$

$$\text{Sensibilidad Neumonía} = \frac{15}{15 + 54} = \frac{15}{69} = 0.21$$

$$\text{Sensibilidad Tuberculosis} = \frac{14}{14 + 56} = \frac{14}{70} = 0.20$$

$$\text{Sensibilidad Normales} = \frac{11}{11 + 59} = \frac{11}{70} = 0.15$$

Valor de Referencia

Tabla 33: Tabla de evaluación del valor de referencia (Optimizador SGD)

Enfermedad	Valor de Referencia
Covid	0.36
Neumonía	0.23
Tuberculosis	0.32
Normales	0.26

Fórmula

$$\text{Valor de Referencia} = 2 \times \frac{\text{Precisión} \times \text{Sensibilidad}}{\text{Precisión} + \text{Sensibilidad}}$$

Resultados

$$V.V.R. \text{ Covid} = 2 \times \frac{0.62 \times 0.27}{0.62 + 0.27} = 2 \times \frac{0.1674}{0.89} = 2 \times 0.1801 = 0.36$$

$$V.R. \text{ Neumonía} = 2 \times \frac{0.71 \times 0.21}{0.71 + 0.21} = 2 \times \frac{0.1491}{0.92} = 2 \times 0.1621 = 0.23$$

$$V.R. \text{ Tuberculosis} = 2 \times \frac{0.77 \times 0.20}{0.77 + 0.20} = 2 \times \frac{0.154}{0.97} = 2 \times 0.1588 = 0.32$$

$$V.R. \text{ Normales} = 2 \times \frac{0.91 \times 0.15}{0.91 + 0.15} = 2 \times \frac{0.1365}{1.06} = 2 \times 0.1288 = 0.26$$

Métricas de evaluación de la prueba 2

Tabla 34: Métricas de evaluación de la prueba 4

Métricas	Covid	Neumonía	Tuberculosis	Normales
Precisión	0.62	0.71	0.77	0.91
Sensibilidad	0.27	0.21	0.20	0.15
Valor de referencia	0.36	0.23	0.32	0.26

En la métrica de precisión la enfermedad Normales tuvo el porcentaje de 91% siendo este el más alto. En la métrica de sensibilidad, la enfermedad que tuvo un mayor porcentaje fue Covid con un 27% y en la métrica de Valor de referencia la enfermedad Covid tuvo el mayor porcentaje con un valor de 36%.

COMPARACIÓN DE LOS MODELOS

En la **tabla 35** se presenta la tabulación de los resultados finales obtenidos de la matriz de confusión de las dos pruebas, presentando una suma total para verdaderos positivos, verdaderos negativos, falsos negativos y verdaderos negativos.

Tabla 35: Tabulación de resultados de la matriz de confusión de los modelos

	Verdaderos Positivos	Falsos Positivos	Verdaderos Negativos	Falsos Negativos
PRUEBA 1	57	23	23	177
PRUEBA 2	58	22	22	218

Con base en los totales obtenidos para cada parámetro de la matriz de confusión de los modelos se ha elaborado los siguientes gráficos, los cuales permiten realizar una comparación.

Verdaderos Positivos




Ilustración 23: Verdaderos positivos de las tablas

Verdaderos Negativos

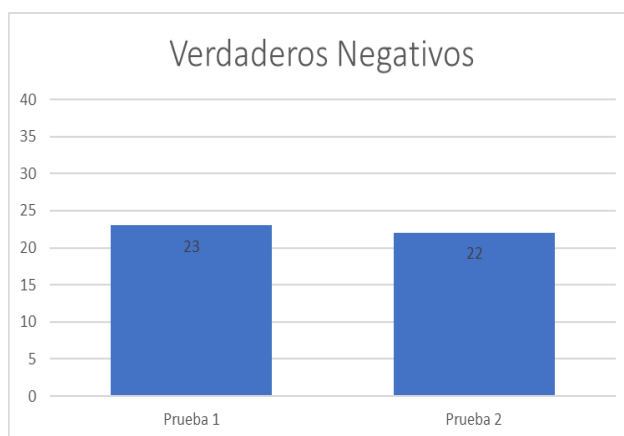


Ilustración 24: Verdaderos negativos de las pruebas

En estos gráficos se visualiza que la prueba 2 tiene mayor cantidad de verdaderos positivos, además tiene el valor más bajo en los verdaderos negativos, lo cual quiere decir que este modelo es el que mejores resultados ofrece en el reconocimiento de Enfermedades, dado que produce menor cantidad de errores en la predicción.

A continuación, se presenta la tabulación de las métricas de rendimiento obtenidas por cada uno de los modelos.

Tabla 36: Métricas de rendimiento de las cuatro pruebas

Métrica	Clase	Prueba 1	Prueba 2
Precisión	Covid	0.60	0.62
	Neumonía	0.71	0.71
	Tuberculosis	0.76	0.77
	Normales	0.91	0.91
Sensibilidad o Recall	Covid	0.27	0.27
	Neumonía	0.21	0.21
	Tuberculosis	0.18	0.20
	Normales	0.15	0.15
Valor de referencia	Covid	0.37	0.36
	Neumonía	0.32	0.23
	Tuberculosis	0.29	0.32
	Normales	0.26	0.26

Con base en estos resultados de las métricas de evaluación, se ha elaborado los siguientes gráficos para establecer una comparación entre los modelos analizados.




Ilustración 25: Precisión de las pruebas

En la métrica de precisión se puede visualizar muy minuciosamente que la prueba 2 tiene mejores.

A continuación, se analiza la métrica de sensibilidad o recall, con base en los resultados presentados en la Tabla x.

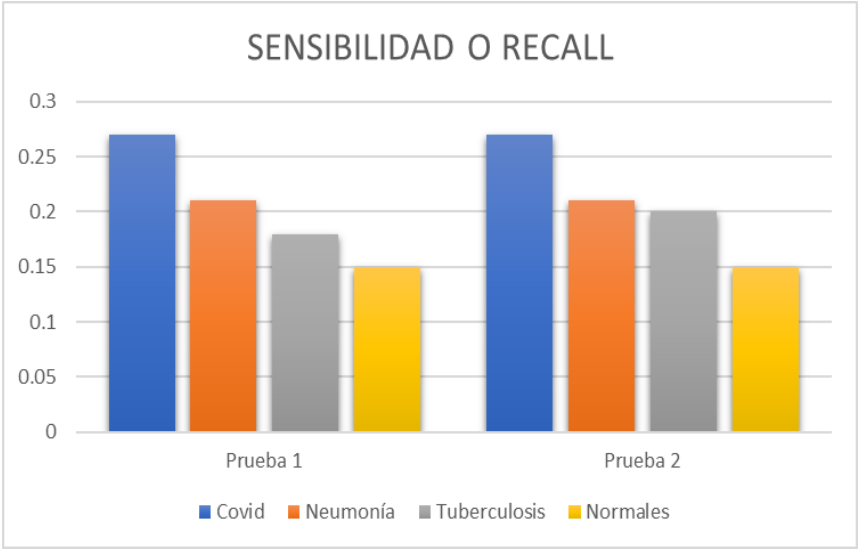


Ilustración 26: Sensibilidad de las pruebas

En la métrica de sensibilidad ambas pruebas tienen valores muy similares, un comportamiento similar se puede observar en la métrica valor de referencia.




Ilustración 27: Valor de referencia de las pruebas

SELECCIÓN LA MEJOR PRUEBA

De todas las pruebas realizadas con el dataset TEST que cuenta con 4000 imágenes, se obtuvo mejores resultados con la prueba 2, el cual cuenta con 200 épocas, el nombre del optimizador es el SGD, el loss es de 0.0189 y el accuracy es de 0.9932.

Resultados de las pruebas con el optimizador SGD

En la Tabla 37 se observa los resultados de la predicción de las radiografías reales de diferentes personas.

Tabla 37: Resultados de las pruebas con radiografías reales

		PREDICCIÓN				
		Covid	Neumonía	Tuberculosis	Normales	TOTAL
REAL	Covid	1	1	0	0	2
	Neumonía	0	1	0	0	1
	Tuberculosis	0	0	2	0	2
	Normales	1	0	0	1	2

Matriz de confusión consolidada de la Tabla 14 de la enfermedad Covid

Tabla 38: Matriz Consolidada de la enfermedad Covid (Optimizador SGD)

		Predicción	
		Enfermedad	No enfermedad
Situación Real	Enfermedad	1	1
	No enfermedad	1	4

Matriz de confusión consolidada de la Tabla 14 de la enfermedad Neumonía

Tabla 39: Matriz Consolidada de la enfermedad Neumonía (Optimizador SGD)

		Predicción	
		Enfermedad	No enfermedad
Situación Real	Enfermedad	1	0
	No enfermedad	1	5

Matriz de confusión consolidada de la Tabla 14 de la enfermedad Tuberculosis

Tabla 40: Matriz Consolidada de la enfermedad Tuberculosis (Optimizador SGD)

		Predicción	
		Enfermedad	No enfermedad
Situación Real	Enfermedad	2	0
	No enfermedad	0	5

Matriz de confusión consolidada de la Tabla 14 de la enfermedad Normales

Tabla 41: Matriz Consolidada de la enfermedad Normales (Optimizador SGD)

		Predicción	
		Enfermedad	No enfermedad
Situación Real	Enfermedad	1	1
	No enfermedad	0	5

Matriz de confusión consolidada de la Tabla 14 de las 4 enfermedades

Tabla 42: Matriz Consolidada de las 4 enfermedades (Optimizador SGD)

Enfermedades	Verdaderos Positivos	Falsos Positivos	Verdaderos Negativos	Falsos Negativos
Covid	1	1	1	4
Neumonía	1	1	0	5
Tuberculosis	2	0	0	5
Normales	1	0	1	5

Métricas de evaluación

Precisión

Tabla 43: Tabla de evaluación de la precisión (Optimizador SGD)

Enfermedad	Precisión
Covid	0.50
Neumonía	0.50
Tuberculosis	1.0
Normales	1.0
Promedio	0.75

Sensibilidad (Recall)

Tabla 44: Tabla de evaluación de la sensibilidad (Optimizador SGD)

Enfermedad	Recall
Covid	0.20
Neumonía	0.16
Tuberculosis	0.33
Normales	0.16
Promedio	0.21

Valor de Referencia

Tabla 45: Tabla de evaluación del valor de referencia (Optimizador SGD)

Enfermedad	Valor de Referencia
Covid	0.14
Neumonía	0.12
Tuberculosis	0.24
Normales	0.14
Promedio	0.16

Para esta prueba se utilizaron una menor cantidad de imágenes obtenidas de familiares, debido a que no se pudo obtener una mayor cantidad de radiografías de hospitales por motivos de privacidad de los pacientes, con los datos obtenidos se puede concluir que la precisión con un número pequeño de radiografías es bueno, pero en el nivel de la sensibilidad o recall nos da resultados que podrían mejorarse con un dataset de radiografías reales más grande.

3.2.2. Resultados de la evaluación de la página web

NIBBLER

Tabla 46: Evidencia de los resultados de la experiencia dentro del sitio web.

Parámetros	Recomendación	Puntaje
Mobile	<ul style="list-style-type: none">• Considere agregar un estilo solo para dispositivos móviles mediante consultas de medios.	3.0
Compartimiento del servidor	<ul style="list-style-type: none">• Asegúrese de que su servidor web devuelva un código de estado HTTP 404 para las páginas de error.• Coloque una redirección permanente (HTTP 301) a http://radiolung.ga en http://www.radiolung.ga.	6.2
Imágenes	Ninguna	10.0
Links internos	Ninguna	10.0
Promedio		7.30

Nota: Las evidencias de los puntajes se pueden observar en los siguientes anexos: Mobile Anexo 5, Servidor de compartimiento Anexo 6, Imágenes Anexo 7, Links internos Anexo 8.

PINGDOM

En la evaluación de la velocidad de la página web nos da un 97/100 con un tiempo de carga de 554ms y un tamaño de página de 231,84kb.



Ilustración 28: Evidencia de los resultados de velocidad del sitio web.

4. CONCLUSIONES

En base a los resultados obtenidos se obtuvieron las siguientes conclusiones:

- ❖ Se logró desarrollar una aplicación web la cual permite el reconocimiento de enfermedades pulmonares implementando redes neuronales convolucionales.
- ❖ Mediante la investigación de artículos científicos se obtuvo información sobre las técnicas de deep learning y una de ellas son las redes convolucionales.
- ❖ Se elaboró una base de datos de radiografías para efectuar la preparación de la red convolucional.
- ❖ Se entrenó la red convolucional usando diferentes optimizadores con distintos parámetros y así elegir la más eficiente.
- ❖ Se finalizó el diseño de la aplicación web que cumplirá con el objetivo de analizar las radiografías utilizando una metodología ágil.
- ❖ Se realizó las respectivas pruebas de reconocimiento en tiempo real con la red preparada de manera satisfactoria.

5. RECOMENDACIONES

En base a los resultados obtenidos se recomienda:

- ❖ Se recomienda que para el entrenamiento de la red neuronal convolucional se utilice una mayor cantidad de optimizadores y una mayor cantidad de épocas para de esta manera obtener resultados más óptimos.
- ❖ Efectuar una investigación más minuciosa en fuentes bibliográficas confiables para incrementar el conocimiento obtenido sobre las técnicas de deep learning y una de ellas son las redes neuronales convolucionales.
- ❖ Para obtener mejores resultados en el entrenamiento y evaluación de resultados se recomienda elaborar una base de datos de radiografías reales.
- ❖ Para realizar el entrenamiento de la red neuronal convolucional se debe utilizar una mayor cantidad de optimizadores con una mayor cantidad de épocas y de esta manera obtener el algoritmo más óptimo o con mejores resultados.
- ❖ Se recomienda realizar una aplicación web con más funcionalidades y también utilizar otra metodología ágil para así poder analizar las radiografías obteniendo resultados más óptimos y detallados de las diferentes enfermedades.
- ❖ Es preciso efectuar diversas pruebas con diferentes tipos de enfermedades para visualizar mejores aspectos en el futuro.

6. RECOMENDACIONES

Para la implementación del sistema de reconocimiento de enfermedades en tiempo aplicando Redes Neuronales Convoluciones se recomienda:

- ❖ Se recomienda que para el entrenamiento de la red neuronal convolucional se utilice una mayor cantidad de optimizadores y una mayor cantidad de épocas para de esta manera obtener resultados más óptimos.
- ❖ Efectuar una investigación más profunda en fuentes bibliográficas para enriquecer el conocimiento obtenido sobre las técnicas de deep learning y una de ellas son las redes neuronales convolucionales.
- ❖ Para obtener mejores resultados en el entrenamiento y evaluación de resultados se recomienda elaborar una dataset con una gran cantidad de radiografías reales.
- ❖ Para realizar el entrenamiento de la red neuronal convolucional se debe utilizar una mayor cantidad de optimizadores con una mayor cantidad de épocas y de esta manera obtener el algoritmo más óptimo o con mejores resultados.
- ❖ Se recomienda realizar una aplicación web con más funcionalidades y también utilizar otra metodología ágil para así poder analizar las radiografías obteniendo resultados más óptimos y detallados de las diferentes enfermedades.
- ❖ Es necesario realizar diversas pruebas con diferentes tipos de enfermedades para poder observar aspectos a mejorar a futuro.

7. REFERENCIAS BIBLIOGRÁFICAS

- [1] B. M. F. NAAR PEREZ AGUSTIN, MODELO DE RED NEURONAL CONVOLUCIONAL PARA EL DIAGNÓSTICO DE NEUMONÍA EN IMÁGENES RADIOLÓGICAS, Cartagena, 2019.
- [2] S. Mukherjee, «Lung Cancer Disease Diagnosis Using Machine Learning Approach,» *International Conference on Intelligent Sustainable Systems (ICISS)*, pp. 1-5, 2020.
- [3] J. Márquez, «Inteligencia artificial y Big Data como soluciones frente a la COVID-19,» *Revista de Bioética y Derecho*, vol. 50, pp. 1-17, 2020.
- [4] W. Morales y R. Guzmán, «Tuberculosis: Diagnóstico mediante procesamiento de imágenes,» *Computación y Sistemas*, vol. 24, nº 2, pp. 1-8, 2020.
- [5] R. S. B. M. B.-T. C. M. M. Darwin PatiñoPérez, «Análisis de Imágenes de Rayos X por Medio de RedesNeuronalesArtificiales,» *ECUADORIAN SCIENCE JOURNAL* , vol. 5, nº 1, pp. 55-60, 2021.
- [6] P. C. D. X. MOROCHO SANDE KEVIN LUIS, ANÁLISIS DE IMÁGENES DE RAYOS X DE COVID-19 A TRAVÉS DE REDES NEURONALES ARTIFICIALES, Guayaquil, 2021.
- [7] M. A. M.-P. V. J. Q.-V. Jose Francisco Ávila-Tomás, «La inteligencia artificial y sus aplicaciones en medicina II: importancia actual y aplicaciones prácticas,» *Atención Primaria*, vol. 53, nº 1, pp. 81-88, 2021.
- [8] M. J. B. Walter H. Curioso, «INTELIGENCIA ARTIFICIAL E INNOVACIÓN PARA OPTIMIZAR EL PROCESO DE DIAGNÓSTICO DE LA TUBERCULOSIS,» *Rev Peru Med Exp Salud Publica*, vol. 37, nº 3, pp. 554-8, 2020.
- [9] P. K. A. B. V. K. N. V. S. B. Raja Sarath Kumar Boddu, «Analyzing the impact of Machine learning and Artificial intelligence and its Effect on Management of lung cancer detection in covid-19 pandemic,» *journal pre-proof*, pp. 3-4, 2021.
- [10] B. A. López, Detección precoz de covid-19 a partir de imágenes de radiografías de torax mediante redes neuronales convolucionales, 3.0 España de Creative Commons, 2021.
- [11] J. K. M. W. J. e. a. Chamberlin, «Automated detection of lung nodules and coronary artery calcium using artificial intelligence on low-dose CT scans for lung cancer screening: accuracy and prognostic value,» *BMC Medicine*, vol. 19, nº 1, 2021.

- [12] R. T. A. C.-C. W. G. J. C. J. B. L. C. R. C. J. R. M. M. D. C. M. G. P. J. L. J. C. R. B. G. B. G. R. G. An Tang, «Canadian Association of Radiologists White Paper on Artificial Intelligence in Radiology,» *Canadian Association of Radiologists Journal*, vol. 69, n° 2, pp. 120-135, 2018.
- [13] B. F. Guarinos, DISEÑO DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL APLICADAS A IMÁGENES MÉDICAS DE RAYOS X PARA LA DETECCIÓN DE ESTRUCTURAS ANATÓMICAS DE LOS PULMONES Y SUS ALTERACIONES, Valencia, 2016.
- [14] A. a. P. P. a. M. Y. a. W. N. Chatchaiwatkul, «Lung Disease Detection and Classification with Deep Learning Approach,» *2021 36th International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC)*, pp. 1-4, 2021.
- [15] C. SFR-IA Group, «Artificial intelligence and medical imaging2018: French Radiology Community white paper,» *Diagnostic and Interventional Imaging*, vol. 99, n° 11, pp. 727-742, 2018.
- [16] A. Kumar Jaiswal, P. Tiwari, S. Kumar, D. Gupta, A. Khanna y J. Rodrigues, «Identifying pneumonia in chest X-rays: A deep learning approach,» *Measurement*, vol. 145, pp. 511-518, 2019.
- [17] S. Goyal y R. Singh, «Detection and classification of lung diseases for pneumonia and Covid-19 using machine and deep learning techniques,» *Journal of Ambient Intelligence and Humanized Computing*, pp. 1-21, 2021.
- [18] U. Lopez y J. Valiati, «Pre-trained convolutional neural networks as feature extractors for tuberculosis detection,» *Computer in Biology and Medicine*, vol. 89, pp. 135-143, 2017.
- [19] J. A. E. d. Castillo, "REDES NEURONALES CONVOLUCIONALES EN LA DETECCIÓN DE AFECCIONES RESPIRATORIAS DE LOS SISTEMAS LOCALES DE SALUD": UNA REVISIÓN SISTEMÁTICA ENTRE LOS AÑOS 2010 Y 2020, Trujillo: UNIVERSIDAD PRIVADA DEL NORTE, 2020.
- [20] J. C. C. PÉREZ, EVALUACIÓN DE MODELOS DE REDES NEURONALES CONVOLUCIONALES APLICADO A RADIOGRAFÍAS DE TÓRAX, PARA APOYAR AL PROCESO DE DIAGNÓSTICO DE NEUMONÍA ASOCIADA AL COVID-19, Lima, 2020.

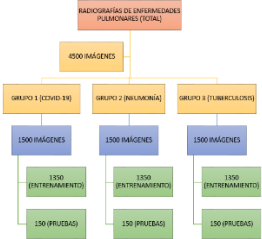
- [21] O. D. V. R. R. P. R. Giuseppe Pezzano, «CoLe-CNN+: Context learning - Convolutional neural network for COVID-19-Ground-Glass-Opacities detection and segmentation,» *Computers in Biology and Medicine*, vol. 136, 2021.
- [22] A. P. Z. I. U. N. d. M. I. P. Juan Carlos Valero Gómez, «Algoritmos de Deep Learning para la detección de Neumonía en infantes a través de imágenes de radiografías del tórax,» *Actas Del Congreso Internacional De Ingeniería De Sistemas*, 2021.
- [23] R. a. R. K. Tekade, «Lung Cancer Detection and Classification Using Deep Learning,» *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)*, pp. 1-5, 2018.
- [24] J. Rachna, N. Preeti, K. Gaurav, S. V. y J. D., «Pneumonia Detection in chest X-ray images using Convolutional Neural Networks and Transfer Learning,» *Measurement*, vol. 165, pp. 1-23, Measurement.
- [25] L. Racic, T. Popovic, S. Cakic y S. Sandi, «Pneumonia Detection Using Deep Learning Based on Convolutional Neural Network,» *International Conference on Information Technology (IT)*, pp. 2-4, 2021.
- [26] L. Deng, S. Sang Ho y X. Yann Lim, «Diseases Classification Utilizing Tooth X-ray Images Based On Convolutional Neural Network,» *International Symposium on Computer, Consumer and Control*, pp. 1-4, 2020.
- [27] N. Mohanapriya, B. Kalaavathi y T. senthil, «Lung Tumor Classification and Detection from CT Scan Images using Deep Convolutional Neural Networks (DCNN),» *International Conference on Computational Intelligence and Knowledge Economy (ICCIKE)*, pp. 1-6, 2019.
- [28] Kaggle, «Kaggle,» 20 12 2021. [En línea]. Available: <https://www.kaggle.com/datasets>.

8. ANEXOS

Anexo1: Matriz de consistencia

Tabla 47: Matriz de consistencia

Problema, objeto y campo	Objetivo	Marco Teórico	Hipótesis	Variables	Metodología
<p>Problema: Necesidad de reconocer automáticamente enfermedades pulmonares en pacientes aplicando redes neuronales artificiales, de un hospital público de la ciudad Machala, durante el periodo 2021-2022.</p> <p>Objeto de estudio: Reconocimiento de enfermedades pulmonares por medio del análisis de radiografías.</p> <p>Campo de Acción: Aprendizaje Automático (Machine Learning), redes neuronales convolucionales (deep learning).</p>	<p>Objetivo General:</p> <ul style="list-style-type: none"> - Desarrollar una aplicación web que utilice redes neuronales artificiales mediante el análisis de radiografías para el reconocimiento de enfermedades pulmonares. <p>Objetivos Específicos:</p> <ul style="list-style-type: none"> - Realizar una búsqueda de la data sobre radiografías de enfermedades pulmonares. - Realizar el entrenamiento y procesamiento de las imágenes. - Diseñar la aplicación web que analizará la radiografía 	<p>Antecedentes históricos a nivel internacional y nacional del objeto, campo:</p> <p>Fundamentos Teóricos de objeto, campo y variables:</p>	<p>Hipótesis General:</p> <ul style="list-style-type: none"> - El desarrollo de una aplicación web con algoritmos de redes neuronales artificiales para el análisis de radiografías y esto permitirá reconocer automáticamente enfermedades pulmonares en pacientes. 	<p>Variable 1 / Independiente:</p> <ul style="list-style-type: none"> - Desarrollo de aplicación web con algoritmos de redes neuronales convolucionales <p>Dimensiones o categorías:</p> <ul style="list-style-type: none"> - Metodologías de desarrollo de aplicación web con IA - Deep learning <p>Variable 2/ Dependiente:</p> <ul style="list-style-type: none"> - Reconocimiento automático de enfermedades pulmonares en pacientes. 	<p>Enfoque: El enfoque será cuantitativo, pues la aproximación al fenómeno será desde la perspectiva del investigador. Para esto se analizarán radiografías a través de técnicas de Deep Learning como Redes Neuronales Artificiales obteniendo resultados en menor tiempo.</p> <p>Alcance: El estudio comenzará como descriptivo y evolucionará a correlacional, en virtud de que se dispone de una población específica acerca de las enfermedades pulmonares y con estas se creará una red neuronal la cual ayudará a que todas estas se relacionen y puedan dar un resultado al analizar una radiografía.</p> <p>Diseño: El diseño de la investigación será causal-experimental porque el estudio se realizará en radiografías de enfermedades pulmonares específicas, las cuales se</p>

	<p>utilizando una metodología ágil.</p> <ul style="list-style-type: none"> - Realizar pruebas de funcionamiento y depuración. 			<p>Dimensiones o categorías:</p> <ul style="list-style-type: none"> - Satisfacción de usuario. - Eficiencia 	<p>dividirán en grupo intactos de imágenes que servirán para pruebas y entrenamiento del algoritmo.</p> <p>Unidades de análisis: Población: 4500 Imágenes de radiografías de enfermedades pulmonares.</p>  <pre> graph TD A[RADIÓGRAFÍAS DE ENFERMEDADES PULMONARES (TOTAL)] --> B[4500 IMÁGENES] B --> C[GRUPO 1 (COVID-19)] B --> D[GRUPO 2 (NEUMONÍA)] B --> E[GRUPO 3 (TUBERCULOSIS)] C --> C1[1500 IMÁGENES] D --> D1[1500 IMÁGENES] E --> E1[1500 IMÁGENES] C1 --> C1a[1300 (ENTRENAMIENTO)] C1 --> C1b[200 (PRUEBAS)] D1 --> D1a[1300 (ENTRENAMIENTO)] D1 --> D1b[200 (PRUEBAS)] E1 --> E1a[1300 (ENTRENAMIENTO)] E1 --> E1b[200 (PRUEBAS)] </pre> <p>Técnicas e instrumentos de recolección de datos: Técnica: Análisis de documentos o datos. Instrumento: Análisis de documentos relacionados al tema y uso de radiografías.</p> <p>Técnicas de procesamiento de datos:</p> <ul style="list-style-type: none"> - Recopilación de artículos científicos - Proceso de búsqueda SRL - Recopilación de datos para el entrenamiento de la red neuronal artificial - Técnicas de deep learning (redes neuronales artificiales)
--	--	--	--	--	---

					<ul style="list-style-type: none">- Cuadros estadísticos para saber la cantidad de artículos por año- Mapas conceptuales
--	--	--	--	--	---

Anexo2: Historias de usuario

Tabla 48: Historia de usuario Nro. 1

Historia de usuario	
Numero: 1	Usuario: Cliente/Administrador
Nombre de la historia: Crear cuenta	
Prioridad en negocio: Alta	
Iteración asignada: 2	
Programador responsable: Ricardo Zhispón, Guillermo Díaz.	
Descripción: Los clientes tendrán la opción de crear una cuenta en el sitio web con la finalidad de guardas sus datos y luego de obtener su predicción se le dará la opción de crear un informe donde se muestran todos sus datos y el resultado final	
Observaciones: Ninguna	

Tabla 49: Historia de usuario Nro. 2

Historia de usuario	
Numero: 2	Usuario: Cliente/Administrador
Nombre de la historia: Ingresar al sistema web	
Prioridad en negocio: Alta	
Iteración asignada: 2	
Programador responsable: Ricardo Zhispón, Guillermo Díaz.	
Descripción: Los usuarios registrados tendrán la opción de ingresar al sistema web con su nombre de usuario y contraseña para tener acceso a las funcionalidades de la página web.	
Observaciones: Ninguna	

Tabla 50: Historia de usuario Nro. 3

Historia de usuario	
Numero: 3	Usuario: Administrador
Nombre de la historia: Hacer predicciones	
Prioridad en negocio: Alta	
Iteración asignada: 3	
Programador responsable: Ricardo Zhispón, Guillermo Díaz.	
Descripción: Los usuarios registrados tendrán la opción de ingresar radiografías al sistema web.	
Observaciones: Ninguna	

Tabla 51: Historia de usuario Nro. 4

Historia de usuario	
Numero: 4	Usuario: Administrador
Nombre de la historia: Visualizar los resultados	
Prioridad en negocio: Alta	
Iteración asignada: 1	
Programador responsable: Ricardo Zhispón, Guillermo Díaz.	
Descripción: Los usuarios registrados tendrán la posibilidad de observar los resultados de las predicciones realizadas.	
Observaciones: Ninguna	

Anexo3: Código del entrenamiento de la red neuronal convolucional

```
def carga_dataset():
    global img_rows
    global img_cols
    global data_path
    global labels_t
    global img_data

    img_data_list=[]
    n_imag=0
    n_imag_array=[]
    n_imag_cont=0

    print('EXTRAYENDO DATASET DE LA SIGUIENTE DIRECCIÓN: '+data_path)
    data_dir_list = os.listdir(data_path)

    for dataset in data_dir_list: #cargar carpeta por carpeta
        img_list=os.listdir(data_path+'/'+ dataset)
        print ('CARGANDO IMÁGENES DE LA CARPETA -> '+'{}\n'.format(dataset))
        for img in img_list: #cargar imagen por imagen
            n_imag+=1
            #print (img)
            input_img=cv2.imread(data_path + '/' + dataset + '/' + img )# imread permite abrir la imagen
            input_img=cv2.cvtColor(input_img, cv2.COLOR_BGR2GRAY)
            input_img_resize=cv2.resize(input_img,(img_rows,img_cols)) #redimensiona al tamaño 128
            img_data_list.append(input_img_resize) #adherir los valores anteriores a un vector
            n_imag_array.append(n_imag) #cantidad de imagenes por carpeta
            n_imag_cont+=1

    img_data = np.array(img_data_list) #transforma a vector para trabajar de mejor manera
    img_data = img_data.astype('float32') #transforma el array en el tamaño float32
    img_data /= 255 #redondear
    img_data = np.expand_dims(img_data, axis=3) #forma

    # Asignar etiquetas
    num_of_samples = img_data.shape[0]
    labels = np.ones((num_of_samples,),dtype='int64')

    labels[0:n_imag_array[0]]=0 # clasificar por medio de un identificador a la informacion de las
    labels[n_imag_array[0]:n_imag_array[1]]=1
    labels[n_imag_array[1]:n_imag_array[2]]=2
    labels[n_imag_array[2]:]=3
    labels_t=labels #guarda a los identificadores en la variable
```

```

▶ #Clasificación de las imágenes
def clasificacion_imagenes(labels_t, num_classes):
    print('SE HAN CARGADO',end=' ')
    print (len(labels_t),end=' ')
    print('IMÁGENES EN TOTAL')
    # convertir las etiquetas de clases a codificación
    Y = np_utils.to_categorical(labels_t, num_classes)

    #Shuffle el dataset
    x,y = shuffle(img_data,Y, random_state=2)
    print('SE HA GENERADO: ', end=" ")
    print(len(x), end=" ")
    print(' VECTORES')
    print('SE HA GENERADO:', end=" ")
    print(len(y), end=" ")
    print('ETIQUETAS')
    # dividir the dataset
    global X_train, X_val, y_train, y_val
    X_train, X_val, y_train, y_val = train_test_split(x, y, test_size=0.15, random_state=2)
    # Definir el modelo
    global input_shape
    input_shape=img_data[0].shape

```

```

[ ] #Creación del modelo
def crear_modelo(input_shape): #capas ocultas de la red neuronal
    global model
    global X_train, X_val, y_train, y_val
    global optimizador
    # ESTRUCTURA DE LA RED NEURONAL
    model = Sequential()
    model.add(Conv2D(32,(3,3),padding='same',input_shape=input_shape)) #CONVOLUCION
    model.add(Activation('relu'))
    model.add(Conv2D(32, (3, 3)))
    model.add(Activation('relu'))
    model.add(MaxPooling2D(pool_size=(2, 2)))
    model.add(Dropout(0.5))
    model.add(Conv2D(64, (3, 3)))
    model.add(Activation('relu'))
    model.add(MaxPooling2D(pool_size=(2, 2)))
    model.add(Dropout(0.5))

```

```

▶ #Guardar el modelo
def guardar_modelo(model):
    # Guradando y cargando el modelo y los pesos
    print('GUARDANDO EL MODELO...')
    model.save('/content/gdrive/MyDrive/DATASET/modelSGD.h5')
    loaded_model=load_model('/content/gdrive/MyDrive/DATASET/modelSGD.h5')
    print('MODELO GUARDADO')

carga_dataset()
clasificacion_imagenes(labels_t, num_classes)
crear_modelo(input_shape)
guardar_modelo(model)

```


Anexo 4: Código del desarrollo de la página web

```
index.html > html > body > section#hero.d-flex.align-items-center > div.container > div.row > div.col-lg-6.d-
1 <!DOCTYPE html>
2 <html lang="en">
3
4 <head>
5   <meta charset="utf-8">
6   <meta content="width=device-width, initial-scale=1.0" name="viewport">
7
8   <title>RadioLung - Tesis</title>
9   <meta content="" name="description">
10
11  <meta content="" name="keywords">
12
13  <!-- Place your kit's code here -->
14  <script src="https://kit.fontawesome.com/716b43d3d1.js" crossorigin="anonymous"></script>
15
16  <!-- Favicons -->
17  <link href="assets/img/favicon.png" rel="icon">
18  <link href="assets/img/apple-touch-icon.png" rel="apple-touch-icon">
19
20  <!-- Google Fonts -->
21  <link href="https://fonts.googleapis.com/css?family=Open+Sans:300,300i,400,400i,600,600i,700,700i">
22
23  <!-- Vendor CSS Files -->
24  <link href="assets/vendor/aos/aos.css" rel="stylesheet">
25  <link href="assets/vendor/bootstrap/css/bootstrap.min.css" rel="stylesheet">
26  <link href="assets/vendor/bootstrap-icons/bootstrap-icons.css" rel="stylesheet">
27  <link href="assets/vendor/glightbox/css/glightbox.min.css" rel="stylesheet">
28  <link href="assets/vendor/remixicon/remixicon.css" rel="stylesheet">
29  <link href="assets/vendor/swiper/swiper-bundle.min.css" rel="stylesheet">
30
31  <!-- Template Main CSS File -->
32  <link href="assets/css/style.css" rel="stylesheet">
33
34  <!-- =====
35  * Template Name: FlexStart - v1.9.0
36  * Template URL: https://bootstrapmade.com/flexstart-bootstrap-startup-template/
37  * Author: BootstrapMade.com
38  * License: https://bootstrapmade.com/license/
39  <!-- ===== Header ===== -->
40  <header id="header" class="header fixed-top">
41    <div class="container-fluid container-xl d-flex align-items-center justify-content-between">
42      <a href="index.html" class="logo d-flex align-items-center">
43        
44        <span>RadioLung</span>
45      </a>
46
47      <nav id="navbar" class="navbar">
48        <ul>
49          <li><a class="nav-link scrollto active" href="#hero">Inicio</a></li>
50          <li><a class="nav-link scrollto" href="#about">Sobre nosotros</a></li>
51          <li><a class="nav-link scrollto" href="#services">Compartir</a></li>
52          <li><a class="getstarted scrollto" href="Analizador-Imagenes.html">Ingresa Ya</a></li>
53        </ul>
54        <i class="bi bi-list mobile-nav-toggle"></i>
55      </nav>
56    <!-- .navbar -->
57  </div>
58 </header>
59 <!-- End Header -->
```

```

<!-- ===== Hero Section ===== -->
<section id="hero" class="hero d-flex align-items-center">
  <div class="container">
    <div class="row">
      <div class="col-lg-6 d-flex flex-column justify-content-center">
        <h1 data-aos="fade-up">Ofrecemos la posibilidad de detectar enfermedades pulmonares</h1>
        <h2 style="text-align: justify;" data-aos="fade-up" data-aos-delay="400">El propósito de Radiolung es facilitar el reconocimiento de enfermedades pul
        <div data-aos="fade-up" data-aos-delay="600">
          <div class="text-center text-lg-start">
            <a href="Analizador-Imagenes.html" class="btn-get-started scrollto d-inline-flex align-items-center justify-content-center align-self-center">
              <span>Ingresa Ya!</span>
              <i class="bi bi-arrow-right"></i>
            </a>
          </div>
        </div>
      </div>
      <div class="col-lg-6 hero-img" data-aos="zoom-out" data-aos-delay="200">
        
      </div>
    </div>
  </div>
</section>
<!-- End Hero -->

<!-- End #main -->
<a href="#" class="back-to-top d-flex align-items-center justify-content-center"><i class="bi bi-arrow-up-short"></i></a>

<!-- Vendor JS Files -->
<script src="assets/vendor/purecounter/purecounter.js"></script>
<script src="assets/vendor/aos/aos.js"></script>
<script src="assets/vendor/bootstrap/js/bootstrap.bundle.min.js"></script>
<script src="assets/vendor/glightbox/js/glightbox.min.js"></script>
<script src="assets/vendor/isotope-layout/isotope.pkgd.min.js"></script>
<script src="assets/vendor/swiper/swiper-bundle.min.js"></script>
<script src="assets/vendor/php-email-form/validate.js"></script>

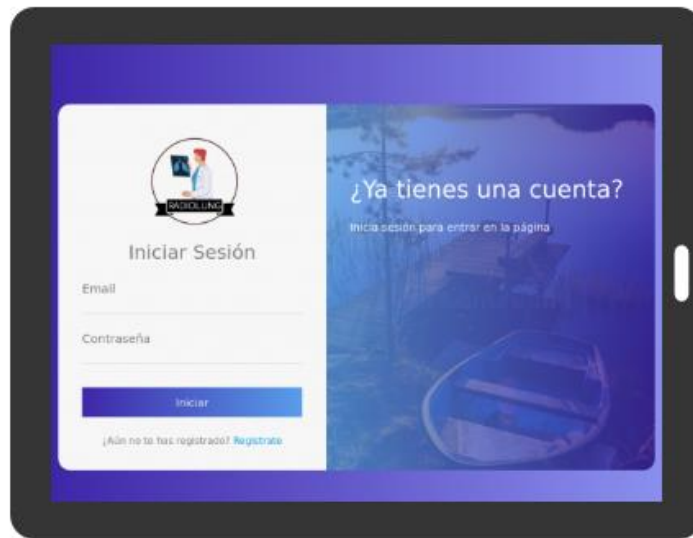
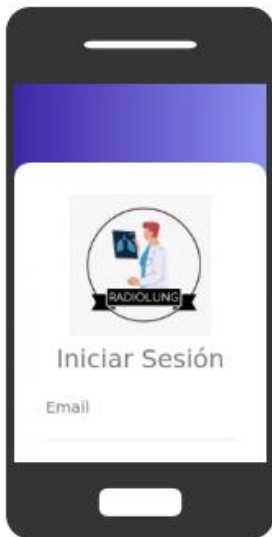
<!-- Template Main JS File -->
<script src="assets/js/main.js"></script>

```

Anexo 5: Mobile puntaje

3.0 Mobile


Help ?




Anexo 6: Servidor de compartimiento

5.6 Server behaviour

[Help ?](#)


404 page


Compression

Anexo 7: Imágenes

10.0 Images

[Help ?](#)



100%
of images have a clearly
defined size

No images
are being resized by the browser

Anexo 8: Links internos

10.0 Internal links

[Help ?](#)



Every link tested appears to be well defined. This is good because well defined links help SEO and aid accessibility.