

PROTOTIPO DE HERRAMIENTA DE SOFTWARE CON APRENDIZAJE DE
MÁQUINAS PARA LA DIFERENCIACIÓN DE NEUMONÍA BACTERIANA O VIRAL
CON EL USO DE RADIOGRAFÍAS DE TÓRAX

SANTIAGO ANDRÉS MARTINEZ TARAZONA

UNIVERSIDAD AUTÓNOMA DE BUCARAMANGA
FACULTAD DE INGENIERÍAS
INGENIERÍA DE SISTEMAS
BUCARAMANGA
2021

PROTOTIPO DE HERRAMIENTA DE SOFTWARE CON APRENDIZAJE DE
MÁQUINAS PARA LA DIFERENCIACIÓN DE NEUMONÍA BACTERIANA O VIRAL
CON EL USO DE RADIOGRAFÍAS DE TÓRAX

SANTIAGO ANDRÉS MARTINEZ TARAZONA

TRABAJO DE GRADO PARA OPTAR POR EL TÍTULO DE: INGENIERO DE
SISTEMAS

DIRECTOR:

CARLOS JULIO ARISMENDI PEREIRA

CODIRECTOR

LILIANA CALDERÓN-BENAVIDES

UNIVERSIDAD AUTÓNOMA DE BUCARAMANGA
FACULTAD DE INGENIERÍAS
INGENIERÍA DE SISTEMAS
BUCARAMANGA
2021

TABLA DE CONTENIDO

	Pág.
1. Resumen	9
1.1 Resumen	9
1.2 Palabras Claves:	9
clasificación, aprendizaje profundo, red neuronal, neumonía, sistema soporte.	9
2. Introducción	11
2.1 Introducción:	11
2.2 Planteamiento del Problema	12
2.3 Objetivo general	13
2.4 Objetivos Específicos	13
3. Estado del arte	14
4. Marco Teórico	16
4.1. Imágenes de rayos-x	16
4.1.1. Diagnóstico médico de enfermedades a partir de imágenes de rayos-x	17
4.2. Técnicas para la detección de enfermedades a partir de imágenes de rayos-x	19
4.2.1. Radiografía	19
4.3. Inteligencia artificial	19
4.3.1. Aprendizaje automático	20
4.3.1.1. Aprendizaje profundo	21
4.3.1.2. Redes neuronales	22
4.3.1.3. Redes neuronales convolucionales	23
4.3.1.4. Técnicas de aumento de datos	24
4.3.5. Técnicas de reducción de dimensionalidad	27
4.3.5.1. Selección de características	27
4.3.5.2. Algoritmo de redundancia mínima y máxima relevancia	28
4.3.6. Técnicas de clasificación	28
4.3.6.1. Árbol de decisión	28
4.3.6.2. Agrupamiento a través de k-means	29

4.3.6.3.	Máquinas de soporte vectorial	29
4.4.	Enfermedades detectables mediante imágenes de rayos-x	30
4.4.1.	Enfermedades respiratorias	30
4.4.2.	Cáncer de seno	32
4.4.3.	Enfermedades cardiovasculares	32
4.5.	Técnicas de preprocesamiento en imágenes	33
5.	Desarrollo metodológico	35
5.1.	Infraestructura tecnológica del sistema	36
5.2.	Metodología de los datos	36
5.2.1.	Base de Datos:	37
5.2.2.	Preprocesamiento de los datos	37
5.1.1	Tecnologías	38
5.1.1.1.	Lenguaje de Programación:	38
5.1.2.	Arquitectura	39
5.1.2.1.	Redes Neuronales	39
5.1.2.2.	Reducción de Dimensionalidad:	41
5.1.2.3.	Máquina de Soporte Vectorial:	41
5.1.3.	Hardware	41
5.3.	Metodología de Prueba	42
5.3.1	Métricas de validación	42
5.4	Diseño de Prototipo	43
6.	Resultados	45
6.1.2.	Arquitectura del Modelo	48
6.1.3.	Fscnca	50
6.1.4.	Máquina de soporte vectorial:	51
6.2.	Diseño del Prototipo.	54
7.	Conclusiones	58
8.	Bibliografía	59

LISTA DE FIGURAS

	Pág.
Figura 1 Espectro electromagnético según su longitud de onda y frecuencia.	16
Figura 2 Representación gráfica del proceso de radiografía.	18
Figura 3 Jerarquía de interacción del deep learning.	20
Figura 4 Red neuronal conectada.	23
Figura 5 Representación de un modelo de CNN.	24
Figura 6 Ejemplo de escalado	24
Figura 7 Ejemplo contraste	25
Figura 8 Ejemplo Afilado	25
Figura 9 Ejemplo rotación	26
Figura 10 Ejemplo suavizado gaussiano	26
Figura 11 Mapeo de SVM.	29
Figura 12 Tórax sano vs Tórax con neumonía.	31
Figura 13 Muerte por neumonía por año en el mundo y en Colombia, de 1990 al 2017.	31
Figura 14 Mamografía.	32
Figura 15 Metodología implementada	35
Figura 16 Desarrollo de la metodología	35
Figura 17 Metodología de los datos	36
Figura 18 Distribución de imágenes de la base de datos de rayos-x de tórax.	37
Figura 19 Comparación de redes neuronales precisión vs uso de gpu.	40
Figura 20 Matriz de confusión.	43
Figura 21 Diagrama de contexto	44
Figura 22 Diagrama de casos de uso	44
Figura 23 Comparación Matlab vs Python Metaclase Norm+Bac vs Virus	45
Figura 24 Comparación Matlab vs Python Metaclase Enfermo vs Normal	46
Figura 25 Comparación tres clases Matlab vs Python	46
Figura 26 Grafica del proceso de reducción de dimensionalidad de las 3 clases	50
Figura 27 Grafica del proceso de reducción de dimensionalidad metaclase Normal+Bacteriana	50
Figura 28 Grafica del proceso de reducción de dimensionalidad metaclase Virus+Bacteriana vs Normal	50
Figura 29 Matriz de confusión modelo final de la base de datos desconocida por el sistema	53
Figura 30 Matriz de confusión modelo final de la base de datos con aumento de datos	54
Figura 31 Interfaz gráfica en su página de inicio	55
Figura 32 Interfaz gráfica selección de imagen de rayos x	56
Figura 33 Interfaz gráfica después de la clasificación	57

LISTA DE TABLAS

	pág.
Tabla 1 Paquetes de aumento de datos	38
Tabla 2 Descripción general de Matlab y Python	39
Tabla 3 Requerimientos funcionales y no funcionales	43
Tabla 4 Tabla de comparación de entrenamientos de VGG16.	47
Tabla 5 Resultado de entrenamiento de las redes VGG-16, RESNET 50 y XCEPTION	48
Tabla 6 Métricas de evaluación de las redes neuronales	49
Tabla 7 Resultado de la energía de los modelos	51
Tabla 8 Sintonización de las SVM respecto a las metaclasses	51

LISTA DE ANEXOS

Anexo 1 Tabla de Resultados Redes Neuronales

pág.
64

1. Resumen

1.1 Resumen

La neumonía es una de las enfermedades más comunes que afecta directamente los pulmones a través de infecciones en las vías respiratorias, además, esta enfermedad puede llegar a ser mortal si no se establece un diagnóstico temprano. De modo que, un diagnóstico adecuado en una etapa temprana de la enfermedad permitiría aplicar un tratamiento apropiado que contribuya a la recuperación del paciente. Así, la radiografía de tórax es uno de los métodos más utilizados y efectivos en el diagnóstico de la neumonía. Sin embargo, el análisis de imágenes de rayos-x de tórax requiere de radiólogos con amplia experiencia para brindar un dictamen acertado sobre el avance de este tipo de enfermedades. En particular, en el área de la salud ha sido ampliamente estudiada esta técnica de diagnóstico basada en imágenes de rayo-x, puesto que, constantemente se busca mejorar la rapidez y precisión de estos diagnósticos médicos para monitorear, controlar y tratar efectivamente las enfermedades, evitando complicaciones a largo plazo, especialmente, en una problemática mundialmente conocida como lo es la neumonía. Por lo tanto, en este trabajo se busca desarrollar una herramienta soporte de software a través de aprendizaje automático y aprendizaje profundo para el análisis de imágenes de rayos-x que permita brindar soporte al personal médico durante un diagnóstico oportuno de neumonía. Asimismo, esta herramienta permitirá evaluar la gravedad de la patología para determinar su tratamiento temprano. Finalmente, con el desarrollo de este tipo de herramientas se podría brindar un servicio de soporte de diagnóstico médico a zonas de Colombia que carecen de especialistas.

1.2 Palabras Claves:

clasificación, aprendizaje profundo, red neuronal, neumonía, sistema soporte.

ABSTRACT

La neumonía es una de las enfermedades más comunes que afecta directamente los pulmones a través de infecciones en las vías respiratorias, además, esta enfermedad puede ser mortal sin un diagnóstico temprano. De modo que, un diagnóstico adecuado en una etapa temprana de la enfermedad permitiría aplicar un tratamiento apropiado que contribuya a la recuperación del paciente. Así, la radiografía de tórax es uno de los métodos más utilizados y efectivos en el diagnóstico de la neumonía. Sin embargo, el análisis de imágenes de rayos-x de tórax requiere de radiólogos con amplia experiencia para brindar un dictamen sobre el avance de la enfermedad. En particular, en el área de la salud ha sido ampliamente estudiada, puesto que, constantemente se busca mejorar la rapidez y precisión de los diagnósticos médicos para monitorear, controlar y tratar efectivamente las enfermedades, evitando complicaciones a largo plazo, especialmente, en una problemática mundialmente conocida como lo es la neumonía. Por lo tanto, en este trabajo se busca desarrollar una herramienta soporte de software a través de aprendizaje automático y aprendizaje profundo para el análisis de imágenes de rayos-x que permita brindar soporte al personal médico durante un diagnóstico oportuno de neumonía. Asimismo, esta herramienta permitirá evaluar la gravedad de la patología para determinar su tratamiento temprano. Finalmente, con el desarrollo de este tipo de herramientas se podría brindar un servicio de soporte de diagnóstico médico a zonas de Colombia que carecen de especialistas.

Pneumonia is one of the most common diseases that directly affects the lungs through respiratory tract infections and can be fatal without an early diagnosis. Then, a proper diagnosis at an early stage of the disease would allow applying an appropriate treatment that contributes to the patient's recovery. Thus, chest radiography is one of the most effective and widely used methods in pneumonia diagnosis. However, the chest X-ray images analysis requires radiologists with extensive experience in order to provide a professional opinion on the progression of the disease. In particular, in the health area, pneumonia has been widely studied, since the speed and accuracy of medical diagnoses are constantly being improved in order to monitor, control, and effectively treat diseases, avoiding long-term complications, especially with such a global issue as pneumonia. Therefore, this work seeks to develop a software support tool through machine learning and deep learning for the X-ray images analysis to provide support to medical personnel for a timely pneumonia diagnosis. This tool will also make it possible to evaluate the severity of the pathology in order to determine its early treatment. Finally, with the development of these types of tools, a medical diagnostic support service could be provided to zones of Colombia those lack specialists.

KEYWORDS:

Classification, deep learning, neural network, pneumonia, support system.

2. Introducción

2.1 Introducción:

Las imágenes médicas han sido una importante herramienta para el diagnóstico y tratamiento temprano de las enfermedades, por ejemplo, la tomografía computarizada, la resonancia magnética, la tomografía por emisión de positrones, la mamografía, el ultrasonido, los rayos X, etc. En particular, técnicas clínicas como las imágenes de rayos-x de tórax, han sido ampliamente utilizadas para el diagnóstico de enfermedades respiratorias, especialmente, la neumonía. Esta patología corresponde a un tipo de enfermedad respiratoria infecciosa que puede ser causada por virus bacterias u hongos.

Por otra parte, la interpretación de estas imágenes de rayos-x son realizadas, en su mayoría, por radiólogos y doctores. Sin embargo, debido a las grandes variaciones en la patología y la posible fatiga de los expertos y los médicos, se han empezado a incluir intervenciones asistidas por computadora que permiten la detección temprana de este tipo de enfermedad.

Asimismo, las técnicas de diagnóstico médico a través de imágenes generan una gran cantidad de datos que a menudo resulta difícil extraer y caracterizar la información necesaria que podría ser útil en la práctica clínica. Algunas técnicas de aprendizaje automático se han implementado como una herramienta objetiva para ayudar a los profesionales a diagnosticar ciertas condiciones y tomar decisiones clínicas. En particular, las técnicas de aprendizaje automático han demostrado repetidamente su utilidad en la medicina. Así que, las posibles aplicaciones de esta tecnología van mucho más allá de lo que se ha utilizado como herramienta de diagnóstico, puesto que, también puede utilizarse para evaluar la gravedad de una patología, realizar la detección temprana de una enfermedad o predecir la evolución de una afección (Consejo et al., 2019).

Por ejemplo, una de las primeras aproximaciones en el área de soporte de diagnóstico médico fue el sistema MYCIN de Shortliffe en 1976, que consistía en un sistema experto diseñado para ayudar a los médicos a tomar decisiones clínicas sobre la elección de opciones de tratamiento adecuadas para los pacientes con diferentes tipos de infecciones (Ker et al., 2017). Por otra parte, en el área de análisis de imágenes médicas, en (Chen et al., n.d.), se combinaron una red neuronal convolucional y una red neuronal recurrente para segmentar estructuras neuronales y fúngicas a partir de imágenes tridimensionales adquiridas a través de un microscopio electrónico. Este trabajo busca diseñar y desarrollar un sistema software especializado basado en inteligencia artificial que permita el diagnóstico médico a través de imágenes de rayos-x.

2.2 Planteamiento del Problema

La neumonía es una enfermedad respiratoria infecciosa muy común, que puede ser causada por virus, bacterias u hongos. Este tipo de enfermedad puede afectar a uno o ambos pulmones. Por una parte, la neumonía se considera una de las mayores causas de muerte en los niños de todo el mundo, además, esta patología es responsable del 15% de todas las muertes de niños menores de 5 años según la Organización Mundial de la Salud (World Health Organization, 2019). Por otra parte, los factores de riesgo para desarrollar neumonía en personas de 70 años o más, son similares a los factores de riesgo que conducen a la neumonía en los niños. De hecho, el número de muertes causadas por neumonía en personas de 70 años o más ha aumentado, específicamente, 1,13 millones de personas murieron de neumonía dentro de este grupo de edad en 2017. Esto se debe a que ha incrementado considerablemente el número de personas que cumplen más de 70 a nivel mundial, aumentando esta tasa de mortalidad, puesto que, este grupo de personas presenta mayor susceptibilidad ante este tipo de patologías (Ritchie, 2019). Así que, es de vital importancia reconocer y tratar rápidamente la neumonía bacteriana, debido a que, si no se detecta de forma temprana, el paciente puede agravar su condición hasta el punto de fallecer (Garnacho-Montero et al., 2010).

Una de las técnicas ampliamente utilizadas para el diagnóstico de enfermedades respiratorias, especialmente, la neumonía, es a través del uso de imágenes de rayos-x de tórax. En general, los médicos de urgencias deben decidir si los resultados de los rayos-x de tórax son congruentes con la neumonía. Un problema importante al confiar en las radiografías de tórax en el diagnóstico de la neumonía está relacionado con la interpretación del médico, debido a que, este tipo de análisis puede estar sujeto a la escasa capacidad de predecir el agente etiológico y el desacuerdo entre los diferentes observadores (Moncada et al., 2011).

De modo que, en el área de salud existen varios métodos para el diagnóstico de neumonía como la prueba de sangre, los hallazgos clínicos, la sintomatología que presente el paciente (siendo una técnica subjetiva), los rayos-x de tórax, entre otros. El principal inconveniente con la neumonía y las diferentes enfermedades respiratorias, es que existe una probabilidad de confundir esta patología con otro tipo de afección (Ebell et al., 2020). Aunque, varios estudios han tratado de señalar las manifestaciones típicas del diagnóstico de neumonía, esta patología puede ser difícil de diagnosticar en pacientes ambulatorios debido a la variabilidad de los resultados obtenidos. Así que, la radiografía de tórax se ha convertido en un estándar fundamental en el diagnóstico de la neumonía (Moberg et al., 2016), puesto que, ha permitido establecer el diagnóstico de esta enfermedad y distinguir esta afección, de enfermedades como la bronquitis aguda (Bartlett et al., n.d.).

Recientemente, algunos trabajos han estudiado el diseño de metodologías de detección de este tipo de enfermedad a partir del uso de radiografías de tórax para brindar soporte a su diagnóstico médico. Especialmente, la técnica de aprendizaje profundo ha permitido la detección de enfermedades respiratorias con alta precisión a partir de imágenes de

diagnóstico médico (Zech et al., 2018; Jaiswal et al., 2019). Por lo tanto, este trabajo de investigación pretende responder a la siguiente pregunta de investigación ¿Cómo incorporar tecnologías de inteligencia artificial en el diseño y desarrollo de un prototipo software especializado que permita brindar soporte al diagnóstico médico de enfermedades respiratorias como la neumonía?

2.3 Objetivo general

Desarrollar un prototipo de sistema de soporte a la clasificación de pacientes con neumonía viral, bacteriana y sin neumonía basado en el análisis de imágenes de rayos-x usando aprendizaje profundo.

2.4 Objetivos Específicos

1. Analizar una base de datos de imágenes diagnósticas de rayos-x de tórax de pacientes con neumonía viral, bacteriana y pacientes sanos.
2. Configurar al menos tres modelos de redes neuronales profundas que permitan realizar la clasificación de las diferentes patologías analizadas.
3. Realizar pruebas de los tres modelos de configuración utilizando las imágenes diagnósticas de pacientes con neumonía viral, bacteriana y pacientes sanos.
4. Desarrollar un prototipo software con interfaz gráfica que permita la clasificación de neumonía en imágenes de rayos-x.

3. Estado del arte

En (Prasoon et al., 2013), se presenta un enfoque para el análisis cuantitativo del deterioro del cartílago de la rodilla en imágenes de resonancias magnéticas con una metodología de aprendizaje profundo e integrando tres redes neuronales convolucionales bidimensionales (2D). Esta metodología en comparación a las redes neuronales convolucionales (CNN, del inglés *Convolutional Neural Networks*) tridimensionales (3D) requiere de un tiempo de entrenamiento menor, y no necesita una gran capacidad de memoria como las CNN 3D, además, este tipo de redes ofrecen un resultado de alta precisión.

En (Roth et al., 2014), se presenta un enfoque para la precisa detección y segmentación de los ganglios linfáticos agrandados que desempeña un papel importante en la clasificación de muchas enfermedades y su tratamiento, por ejemplo, el cáncer de pulmón, el linfoma y la inflamación. Esta detección y segmentación se hace a través de una metodología con imágenes de tomografía axial computarizada usando conjuntos aleatorios de observaciones de la red neuronal convolucional profunda de 2.5 dimensiones, esta metodología, en específico, demostró un alto rendimiento en la reducción de falsos positivos durante el diagnóstico asistido por ordenador.

En (Bar et al., 2015), se analiza la eficacia de los enfoque de aprendizaje profundo para la detección de patologías en las radiografías de tórax haciendo uso de una red neuronal convolucional entrenada con un conjunto de datos no médicos(ImageNet). Se concluye la viabilidad del uso de conjuntos de datos no médicos para detectar patologías en las radiografías de tórax.

En (Litjens et al., 2017), se aborda los principales conceptos de aprendizaje profundo relacionado con análisis de imágenes médicas, y recopila más de 300 contribuciones recientes en el área de aprendizaje profundo para la clasificación de imágenes, la detección de objetos, entre otras, además, se proporcionan descripciones generales de los estudios en diferentes áreas de aplicaciones médicas como el área neurológica, pulmonar, cardiaca, etc.

En (Wang et al., 2018) se presenta un nuevo sistema para abordar los retos de segmentación interactiva en el aprendizaje profundo, debido a que, las redes neuronales convolucionales no generalizan bien los objetos (no vistos) que no estuvieron presentes en el conjunto de entrenamiento. Adicionalmente, se requiere responder rápidamente a las interacciones del usuario y trabajar en una máquina con recursos limitados de la GPU. Este sistema utiliza una segmentación basada en un ajuste detallado (BIFSeg, del inglés *Bounding box and Imagespecific Fine-tuning-based Segmentation*) y una CNN basada en un cuadro delimitadora para la segmentación binaria, que puede segmentar objetos no vistos anteriormente. En este trabajo, se concluye que el BIFSeg logra una precisión similar o mayor

con menos interacciones del usuario y menos tiempo de usuario que los métodos tradicionales de segmentación interactiva.


En (Wang et al., 2018) se presenta un nuevo sistema para abordar los retos de segmentación interactiva en el aprendizaje profundo, ya que las redes neuronales convolucionales no generalizan bien los objetos (No vistos) que no estuvieron presentes en el conjunto de entrenamiento. también se requiere responder rápidamente a las interacciones del usuario y trabajar en una máquina con recursos limitados de la GPU. Este sistema utiliza una segmentación basada en un ajuste detallado(BIFSeg, del inglés *Bounding box and Image-specific Fine-tuning-based Segmentation*) y un CNN basada en un cuadro delimitadora para la segmentación binaria, que puede segmentar objetos no vistos anteriormente. Se concluye que el BIFSeg logra una precisión similar o mayor con menos interacciones del usuario y menos tiempo de usuario que los métodos tradicionales de segmentación interactiva.

4. Marco Teórico

4.1. Imágenes de rayos-x

Los rayos-x fueron descubiertos en 1895 por el físico alemán Roentgen. Los rayos-x son una forma de radiación electromagnética de alta energía, de la misma naturaleza de la luz, pero con una longitud de onda extremadamente corta. En particular, la unidad de medida de los rayos-x es el angstrom(A), igual a, las longitudes de onda de los rayos-x están en el rango de y las frecuencias correspondientes de unos a, como se ilustra en la Figura 1.

Figura 1 Espectro electromagnético según su longitud de onda y frecuencia.



Fuente: La relación de los rayos X con otras radiaciones electromagnéticas dentro del espectro electromagnético. Enciclopedia Británica <https://www.britannica.com/science/bremsstrahlung>

Por otra parte, algunas de las características que definen a los rayos-x son: su capacidad de penetrar materiales ópticamente opacos, sus longitudes de onda de dimensión atómica, la alta energía de los fotones, que conduce a una amplia gama de aplicaciones industriales, médicas y científicas. Así que, se han desarrollado fuentes, detectores y técnicas de análisis de rayos-x especializados para abordar una serie de cuestiones que van desde el estudio de las interacciones de las moléculas hasta la estructura del cerebro humano (Stark, 2020).

En particular, desde el descubrimiento de los rayos-x, las imágenes de rayos-x han desempeñado un papel importante en la organización cognitiva y práctica de la medicina. Este descubrimiento permitió el desarrollo e investigación de diferentes áreas de la ciencia, puesto que, desde el principio se evidenció claramente que los rayos-x tenían un potencial muy grande para la cirugía. Específicamente, la mayoría de las primeras aplicaciones diagnósticas de los rayos-x se realizaron en cirugía, debido a que, se podían visualizar las fracturas de los huesos, fotografiar los cuerpos extraños para determinar su localización, y realizar operaciones con base en la guía del conocimiento exacto de las condiciones anatómicas obtenidas por esta técnica (Pasveer, 1989).

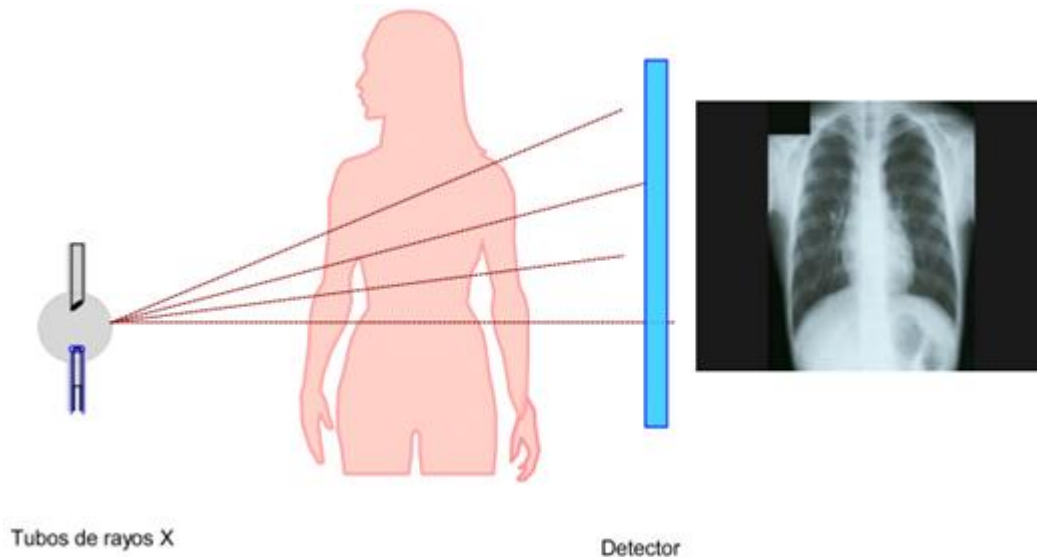
4.1.1. Diagnóstico médico de enfermedades a partir de imágenes de rayos-x

El uso de la tecnología moderna como un complemento efectivo para los procesos diagnósticos e interventores en el área de la salud tuvo uno de sus ápices más importantes en el siglo XX con la aparición de la radiología, siendo este uno de los campos más dinámicos e interdisciplinarios de la salud, dado que es una herramienta presente para diagnosticar o tratar una importante variedad de enfermedades.

Según el Centro Internacional para el Control y Prevención de Enfermedades (CDC, 2018), dentro de las técnicas más utilizadas en la radiología para brindar información sobre el estado de los pacientes se encuentran los rayos-x, la tomografía computarizada, el ultrasonido, fluoroscopia y la resonancia magnética. Estos procesos de adquisición de imágenes se realizan con el objetivo de diagnosticar, tratar y brindar seguimiento a patologías que el paciente pueda presentar, además de tener más información de la condición interna del paciente para tomar las decisiones pertinentes (CDC, 2018).

En este sentido, el radiodiagnóstico consiste en la exploración de las estructuras anatómicas internas con ayuda de la imagen proporcionada por un haz de rayos-x. Este tiene la capacidad de atravesar al sujeto bajo estudio. Específicamente, las estructuras densas, como los huesos, bloquean la mayor parte de estos fotones y se ven de color blanco. El metal y los medios de contraste también se verán de color blanco. Las estructuras que contienen aire se mostrarán negras y los músculos, la grasa y los líquidos como sombras de color gris, como se muestra en la Figura 2 (González A., 2007).

Figura 2 Representación gráfica del proceso de radiografía.



Fuente: Gonzáles, A. (2007). Los rayos X: Unas ondas centenarias en el diagnóstico médico. Barcelona: Universidad de Barcelona.

De modo que, este planteamiento realizado por (Gonzáles, 2007) da contexto acerca de la rama de la radiología que tiene como principal función el diagnóstico de las enfermedades por medio de los llamados rayos-x que como producto tienen las imágenes radiológicas o radiografías. Este proceso se lleva a cabo mediante una exposición del paciente a una liberación controlada de radiación ionizante que permite generar dichas imágenes.

Según lo planteado por (Rodríguez & Martínez, 1997), “los rayos-x constituyen una herramienta ideal para sondear, de manera “no invasiva”, el interior del cuerpo humano”, por consiguiente, el diagnóstico de las enfermedades por medio de los rayos-x se masificó dado su factor poco invasivo y relativamente sencillo de desarrollar. En el ejercicio del radiodiagnóstico de enfermedades mediante rayos-x existen dos variaciones de procedimientos dentro de los estandarizados por uso común: el método común o radiografía convencional que consiste en utilizar un detector plano para generar imágenes de una sola proyección y el sistema digital mediante el cual se hace posible obtener imágenes de lugares específicos del cuerpo del paciente, también llamados sistemas tomográficos (Rodríguez & Martínez, 1997).

4.2. Técnicas para la detección de enfermedades a partir de imágenes de rayos-x

Las técnicas que se utilizan en la rama del radiodiagnóstico enfocado en el uso de rayos-x para definir y dar seguimiento a las enfermedades de los pacientes tienen diferentes instancias, dependiendo de la zona del cuerpo a la que se le haga la proyección de imagen y los procedimientos macro que a estas engloba, son principalmente la radiografía y la tomografía computarizada.

4.2.1. Radiografía

Las radiografías se basan en imágenes radiográficas creadas a partir de rayos-x, que permiten atravesar la zona del cuerpo a la que son expuestos y de esta manera, mediante el uso de diferentes estructuras, se puede realizar la proyección adecuada y obtención de una imagen (Raudales, 2014). La versión original de este procedimiento es la llamada radiografía analógica, en la que la imagen del proceso se obtenía en una placa física y esta era entregada al paciente y/o profesional de la salud, sin embargo, en la época actual se utiliza tecnología moderna que digitaliza y almacena las imágenes radiográficas para su fácil acceso y distribución.

Dentro de la radiografía existen una serie de sub-técnicas que se aplican de acuerdo con la zona del cuerpo que tenga la necesidad de proyectarse para una radiografía, entre estas técnicas con relación anatómica se encuentran:

- Técnicas de exploración radiológica de la extremidad superior.
- Técnicas de exploración radiológica de la extremidad inferior.
- Técnicas de exploración radiológica de la columna vertebral, el sacro y el coxis.
- Técnicas de exploración radiológica del tórax óseo, visceral y abdomen.
- Técnicas de exploración radiológica de cabeza y cuello.

4.3. Inteligencia artificial

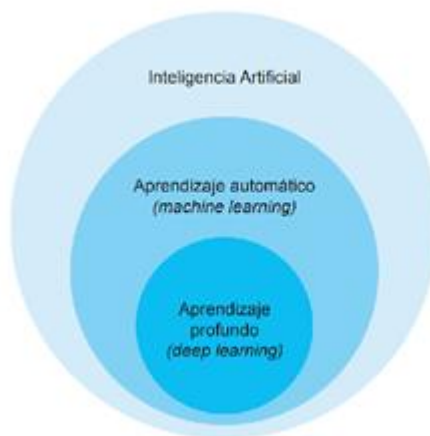
El nacimiento de la Inteligencia artificial se remonta al año 1956, durante una conferencia sobre informática teórica en el *Dartmouth College* en Estados Unidos. En esta conferencia, H. Simon y A. Newell, presentaron un trabajo sobre la demostración automática de teoremas el cual llamaron *Logic Theorist*, este fue el primer programa de ordenador que emulaba características del cerebro humano y por ello se considera el primer sistema de inteligencia artificial de la historia (Benítez et al., 2014).

La Inteligencia Artificial consiste en el uso de tecnología computacional o programas para simular la inteligencia humana, para realizar tareas que normalmente son realizadas por

humanos, como el razonamiento, la interacción, la inteligencia sensorial, entre otros, para tomar decisiones sobre un conjunto de datos recopilados (Tran et al., 2019).

Un sistema de inteligencia artificial requiere de una secuencia finita de instrucciones que especifique las diferentes acciones que ejecuta la computadora para poder resolver un problema en específico. Esta secuencia de instrucciones constituye la estructura algorítmica del sistema (Benítez et al., 2014). Finalmente, en la Figura 3, se señala la jerarquía según las técnicas de aprendizaje dentro del área de inteligencia artificial.

Figura 3 Jerarquía de interacción del deep learning.



Fuente: Gonzáles, A. (2018). Aplicaciones de técnicas de inteligencia artificial basadas en Deep learning al análisis y mejora de procesos industriales. Universidad de Oviedo: Oviedo.

4.3.1. Aprendizaje automático

El aprendizaje automático, a veces también llamado aprendizaje artificial, es una de las ramas de desarrollo de la Inteligencia Artificial utilizado para crear sistemas con el objetivo de resolver problemas que requieran de inteligencia. Sin embargo, se limitan a la solución de problemas ya previstos o informados que se hayan realizado anteriormente.

La Universidad Politécnica de Catalunya expone que estos sistemas están diseñados para tener la inteligencia para analizar el entorno y aprender del mismo, adaptarse, resolver problemas y aprender de los nuevos errores cometidos. Los sistemas de aprendizaje automático no pretenden la imitación del funcionamiento cognitivo de los humanos, sino que apuntan al mejoramiento de las características propias de la inteligencia artificial como el SBC, planificación, TNL, búsqueda, entre otros (Universidad Politécnica de Catalunya, 2015).

Los sistemas de aprendizaje automático funcionan entonces direccionados hacia problemas que tengan un alto nivel de dificultad en materia de programación como lo pueden ser la adquisición de conocimiento, reconocimientos faciales y de voz, entre otros. Además de esto funcionan en casos de aplicaciones autoadaptables, interfases inteligentes, spam filters, sistemas de recomendación, minería de datos y análisis inteligente de datos.

Los tipos de aprendizaje incluidos dentro de aprendizaje automático son:

- Aprendizaje Inductivo
- Aprendizaje Analítico
- Aprendizaje Genético
- Aprendizaje Conexionista

4.3.1.1. Aprendizaje profundo

Este modelo de aprendizaje profundo o *Deep learning* se basa inicialmente en el aprendizaje automático, sin embargo, se diferencia desde el hecho de que el aprendizaje profundo tiene la tendencia a imitar los patrones de pensamiento presentes en el cerebro del ser humano para clasificar información y resolver problemas.

Este concepto parte del macro concepto de las redes neuronales artificiales y se considera un subgrupo dentro del aprendizaje profundo, además de una tendencia emergente en *machine learning*.

En particular, en (González A., 2018), se propone modelar abstracciones de alto nivel de los datos empleando para ello arquitecturas compuestas por un elevado número de capas de transformaciones que pueden ser tanto lineales como no lineales. Se trata de una idea inspirada en la arquitectura y funcionamiento del cerebro humano y, por ello, estas técnicas reciben también el nombre de redes neuronales artificiales. (González A., 2018).

El factor que diferencia al aprendizaje profundo de otras formas de construcción de inteligencia artificial es la capacidad de poder entrenar arquitecturas funcionales profundas y complejas con un número amplio de capas en las que las técnicas tradicionales han fallado debido a problemas de bajo gradiente de peso en las capas internas. (González A., 2018). Este sistema tipo de sistemas permite explotar al máximo los beneficios de la escalabilidad de datos respecto a la cantidad de información procesada en la capa de entrada; cuanto más información se maneje mejor es el rendimiento del sistema.

Adicionalmente, este sistema permite crear redes funcionales de aprendizaje continuo que tienen una gran capacidad de adaptabilidad, además de poder aprovechar otros conceptos innovadores como el Big Data o la industria 4.0. Dentro de las empresas de tecnología más

reconocidas en el mundo estos sistemas de aprendizaje profundo han sido ampliamente utilizados; el sistema de recomendación de Netflix, el reconocimiento de voz de Siri, Google Now y Cortana, el etiquetado de imágenes en Google y Facebook e incluso la tecnología de automóviles autónomos de Tesla, todos estos sistemas se basan en el aprendizaje profundo.

4.3.1.2. Redes neuronales

Las redes neuronales son producto del desarrollo científico para la creación artificial de las capacidades humanas en las máquinas, estas tienen la capacidad de distinguir, memorizar y relacionar hechos por medio de la inteligencia artificial. Estas redes neuronales entonces están basadas en un modelo artificial del cerebro partiendo de su materia básica, la neurona (Ruiz, 2001).


El objetivo de la creación de estas mismas es darle solución al factor común de los problemas que no tienen solución mediante los algoritmos; la experiencia. Los seres humanos tienen la capacidad de almacenar información empírica que se transmite a través de redes que la relacionan con aún más información dentro del cerebro; la intención de las redes neuronales artificiales es imitar este sistema. El cerebro es un órgano que adquiere conocimientos a partir de la experiencia, a través del aprendizaje, y esta es la base de los modelos de redes neuronales. Específicamente, las redes neuronales están formadas por varias unidades simples que trabajan en paralelo, que son el elemento de procesamiento fundamental, la neurona. La neurona biológica recibe información o entradas de otras fuentes, combina la señal de estas entradas y realiza una operación no lineal sobre los resultados de la combinación, el resultado final sería la salida (Sumathi y Paneerselvam, 2010).

Las características principales de las redes neuronales, según el planteamiento de (Ruiz, 2001) son:

- Consisten en unidades de procesamiento que intercambian datos o información.
- Se utilizan para reconocer patrones, incluyendo imágenes, manuscritos y secuencias de tiempo (por ejemplo: tendencias financieras).
- Tienen capacidad de aprender y mejorar su funcionamiento.

Los sistemas de redes neuronales están compuestos por neuronas interconectadas en tres capas, como se presenta en la Figura 4, sin embargo, este número puede variar. La información ingresa a través de la capa de entrada, atraviesan la capa oculta y sale de la capa de salida; la capa oculta es aquella que puede estar constituida por varias capas.

Figura 4 Red neuronal conectada.



Fuente: Ruiz, C. (2001). Redes Neuronales: Conceptos Básicos y Aplicaciones. Rosario: Universidad Nacional.

Además de esto, las redes neuronales tienen un sistema de clasificación que las categoriza de acuerdo a su similitud con la acción biológica de las neuronas en los seres humanos. En primer lugar, está el modelo de tipo biológico, que define las redes que “imitan los sistemas neuronales biológicos, así como las funciones auditivas o algunas funciones básicas de la visión” (Ruiz, 2001, pág. 5); mientras que en el modelo para la aplicación no se guarda similitud con la función biológica del cerebro, dada que su construcción se basa únicamente en el objetivo para el cual fue diseñada.


Finalmente, las ventajas que se obtienen a través de la aplicación de un modelo de redes neuronales son el aprendizaje adaptativo, la tolerancia a los fallos, la operación en tiempo real y la fácil inserción en la tecnología moderna.

4.3.1.3. Redes neuronales convolucionales

Las redes neuronales convolucionales (CNN, del inglés *convolutional neural network*) mantienen información espacial de los datos con pocas conexiones entre las capas. La entrada de esta CNN se organiza en una estructura de rejilla y sus capas preservan estas relaciones. El diseño de la CNN consiste en varias capas de convolución y activación con una capa de agrupación en el medio. La arquitectura básica consiste en: imagen de entrada, capas convolucionales, capas de agrupación y una capa totalmente conectada. La red toma las imágenes de entrada y aplica las capas convolucionales. Esto consiste en aplicar filtros para extraer características (líneas, bordes, orientación, etc.). El resultado es un mapa de características. El siguiente paso es la aplicación de capas de agrupación para reducir el tamaño espacial, lo que lleva a una disminución de los requisitos de potencia de cálculo. Este paso permite la extracción de los rasgos dominantes y reduce el número de neuronas. La acción de la capa convolucional y la capa de agrupación es una convolución. Es posible aplicar varias convoluciones. En cada convolución adicional los mapas de características permiten la extracción de características más complejas. Finalmente, una capa totalmente

conectada conecta la salida de las convoluciones a una capa de salida, donde el número de neuronas es igual al número de clases, como se puede apreciar en la Figura 5 (Bagnato, 2018).

Figura 5 Representación de un modelo de CNN.



4.3.1.4 Técnicas de aumento de datos

Escalado (*Scale*):

Esta transformación cambia el tamaño de la imagen utilizando un factor de escala Δ_s seleccionado aleatoriamente, es decir, $\Delta_s \in [1.18, 1.23]$. Esta transformación redimensiona la imagen con el mismo factor en la dirección horizontal y vertical.

Figura 6 Ejemplo de escalado



Fuente: Documentación Matlab

Contraste:

Esta transformación ajusta el contraste de la imagen mediante un factor de escala Δ_c seleccionado aleatoriamente del rango $[1, 2, 1, 3]$. El contraste aumenta, de modo que las sombras se vuelven más oscuras y las luces más brillantes

Figura 7 Ejemplo contraste




Fuente: Documentación Matlab

Afilado:

Esta transformación enfoca la imagen de entrada en escala de grises, o RGB usando un método de enmascaramiento sin enfoque.

Figura 8 Ejemplo Afilado



Fuente: Documentación Matlab

Rotación:

Esta transformación gira la imagen por grados dependiendo si el valor es positivo o negativo en sentido horario y contra horario a través de su punto central. Hace que la imagen de salida sea lo suficientemente grande como para contener toda la imagen girada, utiliza la interpolación de vecino más cercano, estableciendo los valores de píxeles que están fuera de la imagen girada en (cero).

Figura 9 Ejemplo rotación



Fuente: Documentación Matlab

Suavizado Gaussiano:

Esta transformación añade un filtro a la imagen con un kernel de suavizado gaussiano 2D y con una desviación estándar de 0,5. Para este caso, se incluye un parámetro aleatorio dentro del rango [1, 4].

Se llegó a la conclusión de que debido a la gran diferencia en el número de imágenes entre las clases se requiere utilizar más de un método para poder balancear y lograr un resultado con una diferencia significativa que tuviera un impacto positivo en el entrenamiento. Por ello se distribuyeron los diferentes métodos en 3 paquetes, de la siguiente manera:

Figura 10 Ejemplo suavizado gaussiano



Fuente: Documentación Matlab

4.3.5. Técnicas de reducción de dimensionalidad

En esta sección, se describen algunas técnicas de reducción de dimensionalidad basadas en selección de características.

4.3.5.1. Selección de características

Este método permite reducir la dimensionalidad de los datos al seleccionar sólo un subconjunto de características medidas (variables predictoras) para crear un modelo. El objetivo de los algoritmos de selección de características es buscar un subconjunto de predictores que modele de manera óptima las respuestas medidas, con sujeción a restricciones como las características requeridas o excluidas y el tamaño del subconjunto. Los principales beneficios de la selección de características son que puede mejorar el rendimiento de la predicción, proporcionar predictores más rápidos, y además, permite una mayor comprensión del proceso de generación de datos (Guyon & De, 2003).

Los algoritmos de selección de características se pueden clasificar de la siguiente manera:

Selección de características de tipo filtro: Este algoritmo de selección de características mide la importancia de las características basándose en las características de las propiedades, como la varianza y la relevancia de las características para la respuesta. Se seleccionan las características más relevantes como parte de un paso de preprocesamiento de datos y luego se entrena un modelo utilizando las características seleccionadas. Por lo tanto, la selección de características de tipo filtro no están correlacionadas con el algoritmo de entrenamiento.

Selección de características de tipo envoltura: Este algoritmo de selección de características comienza el entrenamiento utilizando un subconjunto de características y luego agrega o elimina una característica utilizando un criterio de selección. El criterio de selección mide directamente el cambio en el rendimiento del modelo que resulta de añadir o eliminar una característica. El algoritmo repite el entrenamiento y mejora el modelo hasta que el algoritmo cumpla los criterios de parada.

Selección de características de tipo incorporado: Este algoritmo de selección de características aprende la importancia de las características como parte del proceso de aprendizaje del modelo. Una vez terminado el entrenamiento del modelo, se obtiene la importancia de las características del modelo entrenado. Este tipo de algoritmo selecciona características que funcionan bien con un proceso de aprendizaje particular.

Además, se pueden categorizar los algoritmos de selección de características en función de si un algoritmo clasifica las características secuencialmente o no.

4.3.5.2. Algoritmo de redundancia mínima y máxima relevancia

Este algoritmo tiende a seleccionar características con una alta correlación con la clase (salida) y una baja correlación entre ellas. El algoritmo cuantifica la redundancia y la pertinencia utilizando la información mutua de las variables - información mutua de las características por pares e información mutua de una característica y la respuesta. Este algoritmo también es usado para problemas de clasificación.

El objetivo de este algoritmo es encontrar un conjunto óptimo S de características que maximice, además de la relevancia de con respecto a una variable de respuesta, y que minimice, la redundancia de, donde n y k están definidos con información mutua: donde n es el número de características en el conjunto.

4.3.6. Técnicas de clasificación

En esta sección, se presentan algunas técnicas comúnmente utilizadas en tareas de clasificación.

4.3.6.1. Árbol de decisión

El algoritmo de árbol de decisión es el algoritmo más utilizado en clasificación. Los árboles de decisión proporcionan una técnica de modelado fácil de entender y simplifican el proceso de clasificación. El árbol de decisiones es un mecanismo transparente que permite a los usuarios seguir fácilmente la estructura del árbol para ver cómo se toman decisiones.

El propósito principal de un árbol de decisión es generar un modelo que pueda calcular los valores de las variables requeridas basándose en muchas variables de entrada.

En términos generales, todos los algoritmos del árbol de decisión se construyen en dos etapas. En la primera etapa, el conjunto de entrenamiento basado en el criterio óptimo local se divide de forma recursiva hasta que la mayoría de los registros pertenecen a la partición y tienen la misma etiqueta de clase, esto se denomina el crecimiento del árbol. En la segunda etapa, se reduce el tamaño del árbol, lo que facilita su comprensión, esto se denomina la poda de árboles (Soofi & Awan, 2017).

4.3.6.2. Agrupamiento a través de k-means

K-Means es uno de los algoritmos de aprendizaje no supervisado más simples para resolver el problema de agrupamiento. El proceso sigue un método simple que clasifica un conjunto de datos dado por un cierto número de grupos fijados a priori.

El objetivo principal es definir los centros, uno para cada grupo. Estos centroides deber ser colocados correctamente debido a que una ubicación diferente conduciría a diferentes resultados, Por lo tanto, la mejor opción es colocarlos lo más lejos posible entre sí. El siguiente paso es tomar cada punto perteneciente a un determinado conjunto de datos y asociarlo a su centroide más cercano. En particular, esta técnica busca minimizar la siguiente función objetivo


donde es una partición del conjunto de entidades representado por los vectores en el espacio n -dimensional, que consiste en grupos no vacíos y no superpuestos, cada uno con un centroide.

4.3.6.3. Máquinas de soporte vectorial

Las máquinas de soporte vectorial (SVM, del inglés *support vector machine*) son clasificadores vectoriales que aprenden la superficie decisión de dos clases distintas de los puntos de entrada. Están basadas entonces en la minimización del riesgo estructural, además de que han mostrado ser más efectivas que las máquinas tradicionales de aprendizaje como las redes neuronales (Betancourt, 2005).

Estas máquinas primero mapean los puntos de entrada a un espacio de una dimensión mayor, para luego encontrar un hiperplano que los separe y maximice el margen m entre las clases en este espacio, como se ilustra en la Figura 6.

Figura 11 Mapeo de SVM.



Fuente: Betancourt, G. (2005). Las máquinas de soporte vectorial. *Sciencia et technica*, 67-72.

Además, en (Betancourt, 2005) se afirma que estos sistemas son clasificadores biclase, sin embargo, el algoritmo de programación cuadrática de los mismos puede tener modificaciones para permitir el análisis multiclase mediante diferentes fórmulas y organización inteligente de los datos.

Dentro del funcionamiento de las SVM se pueden encontrar diferentes bases teóricas aplicables al planteamiento de problemas de clasificación; entre los más destacados se encuentran:

- Casos linealmente separables
- Casos no linealmente separables
- Variación de kernel para casos no linealmente separables
- Regresión
- Ranking
- *Clustering* o agrupamiento
- Regresión de la dimensionalidad

4.4. Enfermedades detectables mediante imágenes de rayos-x

Los procedimientos de imagenología por medio de técnicas que hacen uso de rayos-x son de las más efectivas y utilizadas alrededor del mundo, dado que, como se expuso anteriormente, tienen la capacidad de detectar un gran número de enfermedades por medio de las proyecciones y creación de imágenes de la anatomía del paciente para su posterior análisis en busca de anomalías que indiquen la presencia de una patología.


Dada su gran difusión, estas técnicas tienen un amplio alcance en el diagnóstico de enfermedades de todo tipo. A continuación, se describen algunas de las patologías que pueden ser detectadas mediante radiografía o tomografía computarizada.

4.4.1. Enfermedades respiratorias

Las enfermedades o afecciones respiratorias son complicaciones que tienen como punto focal el tórax, específicamente, la zona de los pulmones. Para los casos en los que esta zona es afectada por síntomas como fiebre, sople tubárico, distermia, taquicardia, taquipnea, percusión torácica mate, crepitantes, roncus y disminución del murmullo se remite al paciente a una radiografía o tomografía de tórax, posteriormente, el profesional de la salud verifica si existe presencia de una infección u otro tipo de patología. Una de las más comunes que se diagnostican por medio de imágenes radiológicas es la neumonía. En particular, la neumonía

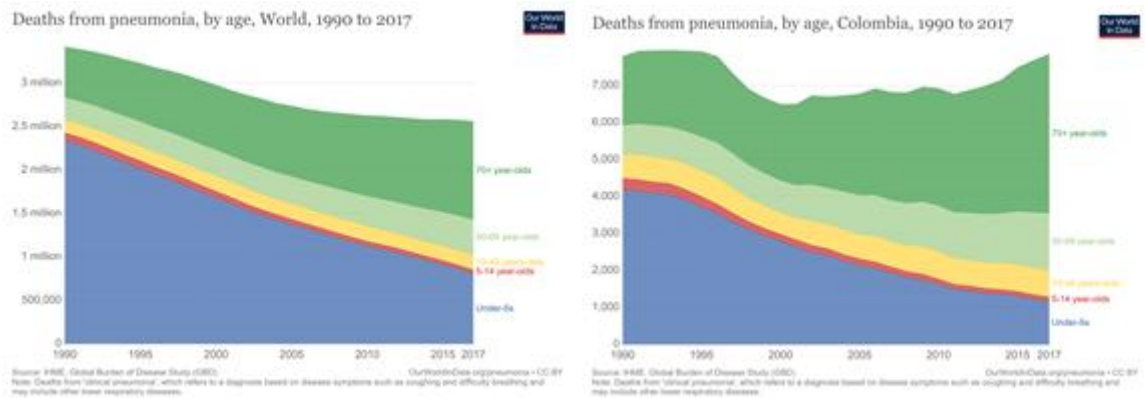
se puede detectar a través de un procedimiento de radiografía de tórax, en el que, según lo planteado por Gil, Fernández & Sabbagh (2002) “se permite confirmar el diagnóstico clínico, establecer su localización, extensión y gravedad; además permite diferenciar la neumonía de otras patologías, detectar posibles complicaciones, y puede ser útil en el seguimiento de los pacientes de alto riesgo” (Gil, Fernández, & Sabbagh, 2005), en la Figura 7, se ilustra dos imágenes de rayos-x correspondientes a un tórax sano y un tórax con neumonía. Este tipo de enfermedad presenta una alta mortalidad a nivel mundial y en Colombia, en la Figura 8 se presenta un resumen del número de muertes causadas por neumonía entre 1990 y 2017.

Figura 12 Tórax sano vs Tórax con neumonía.



Fuente: Mayo Clinic. (13 de Marzo de 2018). Diagnóstico de Neumonía. Obtenido de Enfermedades y Afecciones: <https://www.mayoclinic.org/es-es/diseases-conditions/pneumonia/diagnosis-treatment/drc-2035421>

Figura 13 Muerte por neumonía por año en el mundo y en Colombia, de 1990 al 2017.



Fuente: Bernadeta Dadonaite (2018) - "Pneumonia". Publicado en línea OurWorldInData.org. Obtenido de: <https://ourworldindata.org/pneumonia>

4.4.2. Cáncer de seno

El cáncer es una enfermedad que tradicionalmente se diagnostica y se trata mediante procesos que incluyen el uso de la radiación. En el radiodiagnóstico, muchos son los casos en que las imágenes de las radiografías son consideradas la prueba principal para dictaminar el diagnóstico de cáncer. Uno de los más comunes y detectados por este medio es el cáncer de seno.

El cáncer de seno puede ser diagnosticado mediante una mamografía, la cual se refiere a una radiografía detallada de los senos en búsqueda de carcinomas o anomalías en el interior de estos, como se presenta en Figura 9.

Figura 14 Mamografía.



Fuente: Instituto Nacional del Cáncer. (26 de Noviembre de 2018). Significado de cambios y afecciones de los senos. Obtenido de Cáncer de Seno: <https://www.cancer.gov/espanol/tipos/seno/significado-cambios-en-los-senos>

4.4.3. Enfermedades cardiovasculares


Las pruebas de imágenes para detectar complicaciones cardiovasculares pueden ser muy variadas, incluyendo procedimientos como la ecocardiografía, la radiografía de tórax, la tomografía computarizada y la resonancia magnética. Asimismo, se utilizan otros procesos como la angiografía coronaria.

En el proceso de estas imágenes radiológicas se consideran principalmente tres imágenes para el análisis del profesional la visión de frente, perfil, cavidades cardiacas en un corte axial mediante tomografía computarizada y posterior (Forlino, 2006).

La cardiomegalia es una de las complicaciones cardiovasculares con mayor facilidad de diagnóstico mediante una radiografía de tórax. Esta se presenta en las imágenes dando cuenta del agrandamiento del corazón de manera inusual. Suele ser el signo principal de otras

enfermedades cardiovasculares como debilitamiento del músculo cardíaco, enfermedad de las arterias coronarias, problemas de las válvulas o ritmos cardíacos anormales, como se representa en la Figura 10.

Figura 10 Radiografía de tórax corazón sano vs corazón con cardiomegalia.



Fuente: Forlino, D. (2006). *Semiología Radiológica Básica Cardiovascular del Tórax*. Obtenido de Cátedra de Diagnóstico de Imágenes

4.5. Técnicas de preprocesamiento en imágenes

El procesamiento de imágenes tiene que ver con la adquisición, transmisión, procesamiento y representación de las imágenes. Las técnicas de proceso de imágenes se utilizan para mejorar la apariencia visual de las imágenes para un observador y para preparar convenientemente el contenido fotográfico de cara a la percepción por parte de máquinas (González D., 2010):

Colocando estas definiciones en el contexto de la presente investigación, el procesamiento de imágenes médicas tiene ciertos criterios dependiendo del tipo de imagen requerida en el momento. Comenzando por definir cada una, las imágenes de radiografía son imágenes monocromáticas que pueden ser análogas o digitales que capturan la variación espacial de los rayos-x en una placa o imagen digital.

Por otro lado, la tomografía computarizada axial son imágenes con cortes axiales y bidimensionales que permiten ver cualquier parte del cuerpo humano mediante una pantalla o una película plana en blanco y negro (Restrepo, 1998).

Las técnicas de procesamiento de imágenes radiológicas tienen tres fases: a) preprocesamiento, b) segmentación-registro, c) clasificación. Además, pueden variar según la necesidad que se considere relevante para este mismo. Esto se lleva a cabo en el momento de preprocesar una radiografía digital.

El preprocesamiento de imágenes de rayos-x es importante dado que puede soliviar aspectos no controlados en la toma de las imágenes médicas como el equipo de imagen, sistema de grabación, equipos de procesamiento y almacenamiento de imágenes de rayos-x. Tiene la capacidad de mejorar en la calidad de la imagen para su posterior análisis en elementos, puesto que, permite realzar el contraste, incrementar la nitidez y corregir deficiencias en la adquisición de las imágenes debido principalmente a factores como: a) variaciones de iluminación, b) movimientos voluntarios o involuntarios del paciente, c) solapamiento de huesos, y d) presencia de gas en el colon; que producen sombras o borrosidades en la imagen de rayos-x (Estacio, 2018). Además, el preprocesamiento de imágenes de rayos-x ayuda con factores como:

- La corrección de deficiencias en la adquisición de datos para resultados satisfactorios en etapas posteriores.
- Reducción o eliminación del nivel de ruido contenido en la imagen
- Mejoramiento de la apariencia visual
- Preparación para medidas y análisis
- Normalizar las imágenes para establecerlas en un espacio geométrico o de intensidad específico (Estacio, 2018).

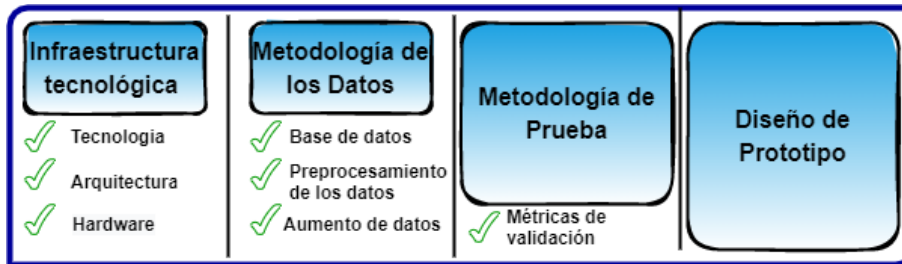
Por último, las técnicas más utilizadas para el preprocesamiento de las imágenes médicas tanto de radiografías como de tomografía computarizada axial y resonancia magnética son:

- Ecuilización de Histogramas (HE)
- Corrección Gamma (GC)
- Ecuilización de Histograma Adaptativo (AHE)
- Ecuilización de Histogramas Adaptativo Limitado por el Contraste (CLAHE)

5. Desarrollo metodológico

En esta sección, se describe el desarrollo metodológico que corresponde a las actividades propuestas durante la etapa de investigación, asimismo, el desarrollo y cumplimiento de cada uno de los objetivos planteados.

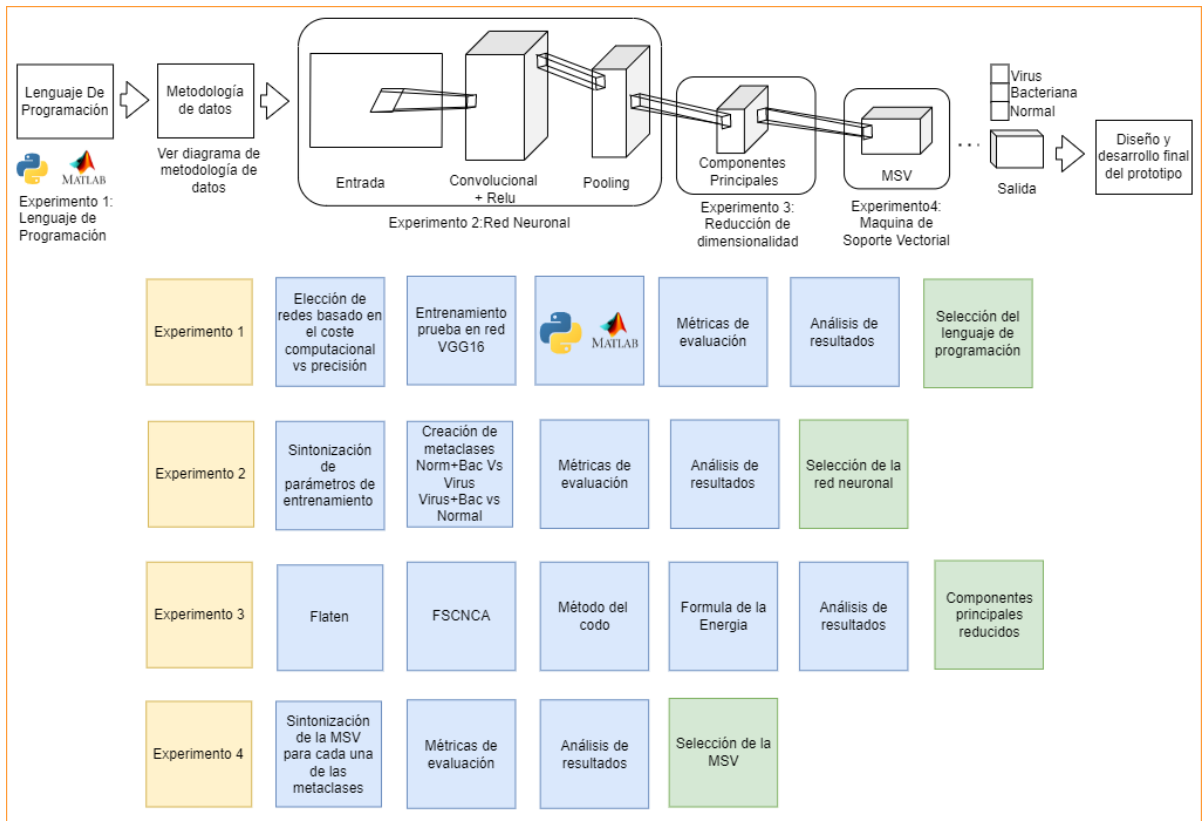
Figura 15 Metodología implementada



Fuente: Propia

En la siguiente gráfica se explica de manera más detallada cómo se desarrolló la metodología anteriormente descrita, y los diferentes experimentos realizados para la elección de las características del modelo final.

Figura 16 Desarrollo de la metodología



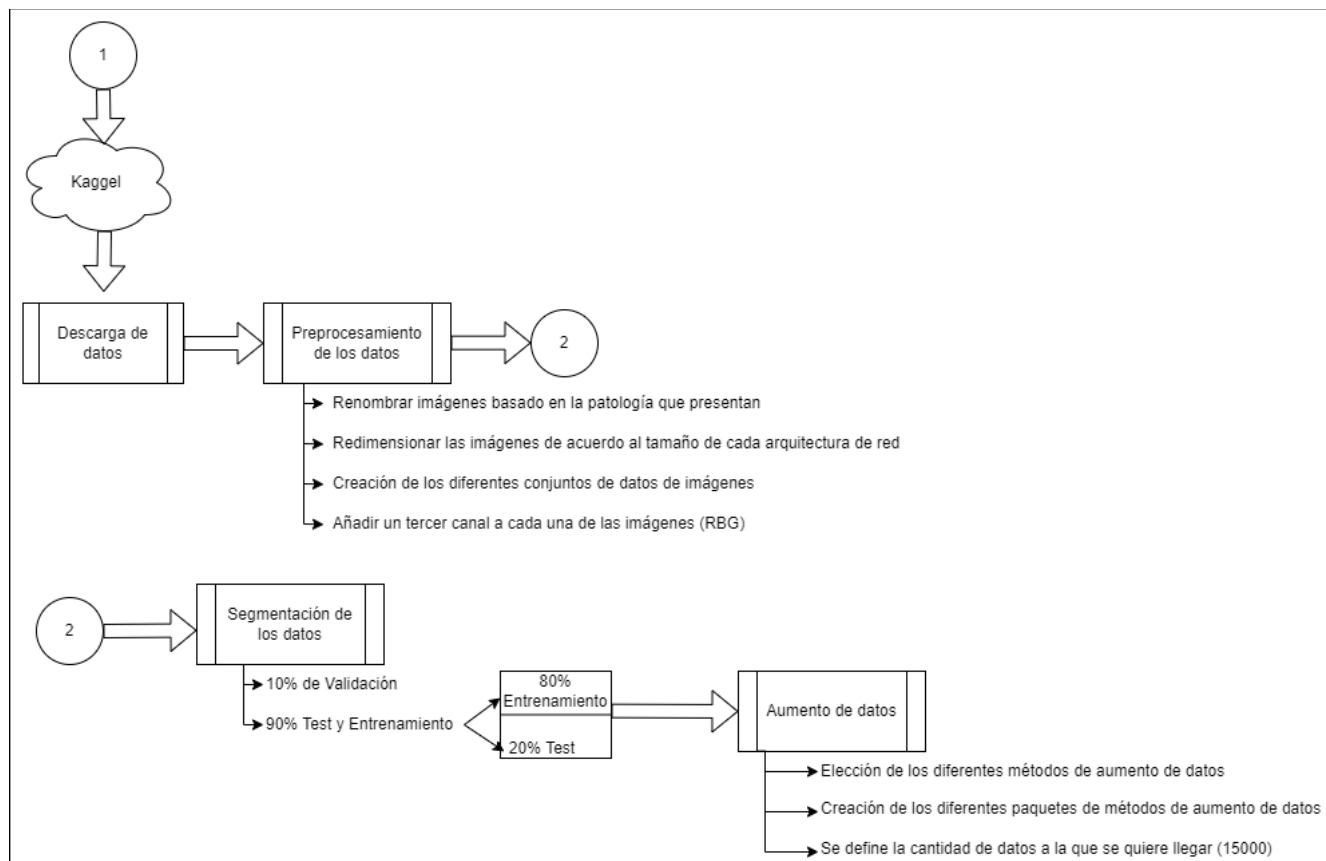
Fuente: Propia

5.1. Infraestructura tecnológica del sistema

5.2. Metodología de los datos

Uno de los factores principales para el entrenamiento de las redes neuronales son los datos, especialmente, en el problema de clasificación de imágenes médicas es importante el correcto etiquetado de los datos para la clasificación de diferentes etiologías de infección pulmonar, adicionalmente, los resultados dependerán en gran medida de la confiabilidad de los datos utilizados durante la etapa de entrenamiento.

Figura 17 Metodología de los datos



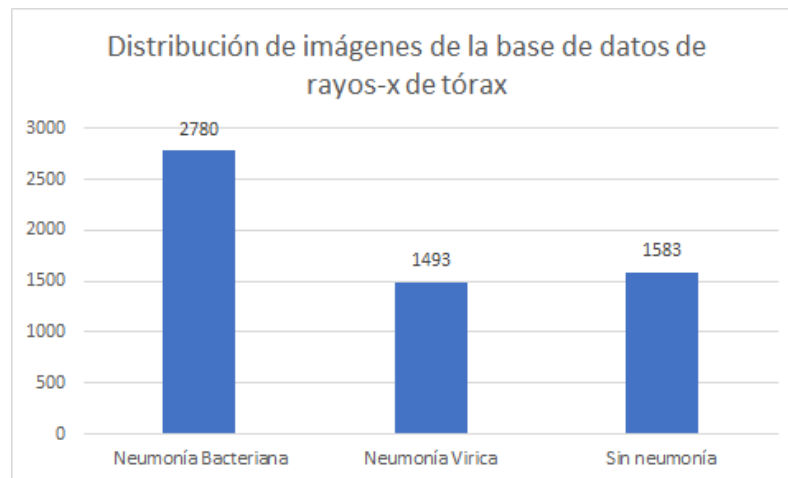
En este cuadro representa la metodología de datos usada, desde la descarga de datos, preprocesamiento hasta la segmentación y aumento de datos que va a ser explicado a lo largo de este segmento.

5.2.1. Base de Datos:

Por ello, para el análisis de las imágenes de rayos-x de tórax, todas las radiografías de tórax se examinaron inicialmente para el control de calidad eliminando todas las exploraciones de baja calidad o ilegibles. Los diagnósticos de las imágenes fueron calificados por dos médicos expertos antes de ser aprobados para el entrenamiento del sistema de inteligencia artificial. A fin de tener en cuenta cualquier error de clasificación, el conjunto de evaluación también fue comprobado por un tercer experto (Kermany et al., 2018).

Esta base de datos está organizada en 3 carpetas (entrenamiento, prueba, validación), distribuidas como se muestra en la Figura 12. Adicionalmente, esta base de datos contiene subcarpetas para cada categoría de imágenes (Neumonía/Normal). A su vez, la carpeta de neumonía abarca dos tipos de neumonía: viral y bacteriana. De modo que, se tendría un total de 5.863 imágenes de rayos-x en formato (JPEG).

Figura 18 Distribución de imágenes de la base de datos de rayos-x de tórax.



Fuente: Propia

5.2.2. Preprocesamiento de los datos

Debido a la diferencia entre la cantidad de imágenes de cada clase, es necesario balancear la base de datos antes de ser dividida en entrenamiento, validación y prueba. Por lo cual, se hace una investigación de los diferentes métodos de aumento de datos, además de los métodos usados en trabajos similares de este modo, seleccionando los más acordes. Sin embargo, se tomó el 10% correspondiente al número de imágenes de cada clase, antes de

realizar el aumento de datos para nuestro conjunto prueba, con el fin de determinar la sensibilidad real con imágenes completamente desconocidas para la red.

Tabla 1 Paquetes de aumento de datos

Paquete 1:	Rotación + Contraste + Escalado.
Paquete 2:	Rotación + Afilado + Escalado
Paquete 3:	Rotación + Suavizado + Gaussiano + Escalado

Fuente: Propia

Una vez aplicado las diferentes técnicas de aumento de datos, tomando en cuenta el porcentaje y la diferencia existente entre las clases, se logró aumentar el dataset de 5863 imágenes a 15000. La distribución que se eligió para la base de datos fue la siguiente:

5.1.1 Tecnologías

El entorno de desarrollo es una de las características más importantes a tener en cuenta. Por ello se hizo una investigación de los lenguajes de programación más usados para proyectos de aprendizaje de máquinas, de los cuales previamente se escogieron dos para ser testeados.

5.1.1.1. Lenguaje de Programación:

Una de las características importantes a elegir era el lenguaje en el cual se desarrollará el modelo. Se tuvieron en cuenta dos de los más usados para el desarrollo de modelos de aprendizaje profundo, los cuales fueron:

Tabla 2 Descripción general de Matlab y Python

	Matlab	Python
Descripción general	Es una plataforma y lenguaje de programación de alto nivel, enfocado al análisis de datos, cálculo numérico, y creación de modelos, es una plataforma paga, por lo cual no suele ser el lenguaje de programación elegido en proyectos independientes.	Es un lenguaje de programación orientado a objetos, de código libre, siendo este muy popular en el desarrollo de inteligencia artificial, con frameworks como Pytorch o tensorflow.
Velocidad	Moderada	Alta
Producción	Visión computacional	Tareas generales
Costo	Pago	Gratuito
Comunidad	Moderada	Alta

Fuente: Gonzáles

En el proceso de análisis del lenguaje de programación a usar no tuvimos en cuenta el costo de Matlab, debido a que, la Universidad provee la licencia de forma gratuita. Se hizo un primer acercamiento en ambos lenguajes, y se pudo concluir, de manera empírica, las facilidades que provee Matlab, por lo fácil de su instalación, la interfaz de usuario intuitiva, y la vasta biblioteca de herramientas (*Toolboxes*) y aplicaciones integradas para crear diagramas personalizados, para el análisis de datos, y para el desarrollo de interfaces de usuario personalizadas de forma rápida y sencilla gracias a su aplicativo “*app designer*”. Por otra parte, el lenguaje de programación Python se utilizó para el entrenamiento y prueba de las arquitecturas de redes neuronales implementadas a partir de la herramienta de google colab.


5.1.2. Arquitectura

5.1.2.1. Redes Neuronales

En esta sección, se discuten los 3 modelos neuronales escogidos para la clasificación de imágenes, los cuales presentan diferente costo computacional y precisión de clasificación.

En primer lugar, en la Figura 11 se ilustra el comportamiento en términos de precisión según la predicción de cada una de las redes neuronales a partir de diferente número de GPUs.

Figura 19 Comparación de redes neuronales precisión vs uso de gpu.



Fuente: *Pretrained Deep Neural Networks - MATLAB & Simulink - MathWorks América Latina*. Publicado en línea [la.mathworks.com](https://la.mathworks.com/help/deeplearning/ug/pretrained-convolutional-neural-networks.html). Obtenido de: <https://la.mathworks.com/help/deeplearning/ug/pretrained-convolutional-neural-networks.html>

En la documentación de matlab, se muestra una gráfica a detalle las diferentes redes pre entrenadas disponibles, respecto a su precisión y costo computacional específico, además se puede apreciar en color rojo la posición de las redes elegidas, se eligió una red de costo computacional bajo, medio y alto que corresponde a las redes Vgg-16, Resnet-50 y Xception, respectivamente, para hacer la respectiva comparación que está detallada en la metodología de métricas.

5.1.2.2. Reducción de Dimensionalidad:

Previamente en la parte investigativa se hizo un análisis de las ventajas y desventajas de la reducción de dimensionalidad, en donde se pudo evidenciar que cuando se realiza una reducción de dimensionalidad, pese a que se tiende a perder hasta un 15% de la variabilidad en los datos originales, el realizar este procedimiento tiene consigo muchas ventajas como lo son, menor tiempo de entrenamiento, el uso de menos recursos computacionales para la ejecución y análisis de las mismas y sobre todo, aumenta el rendimiento general de los algoritmos que usan estos datos como muestras.(Musić et al., 2014.)

Se hizo uso del algoritmo fscnca (del inglés *Feature selection using neighborhood component analysis for classification*), el cual es un algoritmo de selección de características mediante el análisis de vecinos próximos para poder obtener las características principales.

5.1.2.3. Máquina de Soporte Vectorial:

A partir de las características principales se decidió utilizar una máquina de soporte vectorial para separar las diferentes clases en el hiperplano y obtener una precisión mayor en la clasificación, aunque, el algoritmo de las máquinas de soporte vectorial está formulado para problemas de clasificación binaria, se ha evidenciado su eficacia en la clasificación multiclase, puesto que, este tipo de clasificación reduce los problemas multiclase en problemas binarios.

5.1.3. Hardware

Debido a que se seleccionaron redes neuronales con diferentes costos computacionales, se requirió de un equipo de cómputo de alto rendimiento para el entrenamiento de las diferentes redes. Específicamente, el equipo de cómputo utilizado contiene una tarjeta gráfica NVIDIA 2080 ti con RAM virtual de 12 GB y RAM física de 64 GB con un procesador Intel Core i9-12900k de 16 núcleos.

5.2.3.1. Distribución del conjunto de datos aumentado

Como se explicó al inicio de esta sección, se tomó el 10% de cada una de las clases, para poder tener un control más que evaluará la sensibilidad del modelo, que corresponde a 270 imágenes de neumonía bacteriana, 158 imágenes de neumonía viral, 149 imágenes de la clase normal, para un total de 577 Imágenes.

Las 15000 imágenes del dataset se distribuyeron de la siguiente forma: se tomó el 60% para el training(12000), 20% para Test y otro 20% para la validación

5.3. Metodología de Prueba

La selección de la red neuronal se realizó a través del el entrenamiento de las 3 redes utilizadas variando algunos parámetros de entrenamiento, tales como, el número de épocas, el algoritmo de optimización, el tamaño del *batch*, con el fin de determinar no solamente la arquitectura de red neuronal más adecuada, sino de las características del entrenamiento más apropiadas.

5.3.1 Métricas de validación

Exactitud (Accuracy). Se refiere a la media de sesgo estadístico, error relativo o absoluto, que se utiliza para describir la proximidad de una medida al valor real. En este caso en específico se refiere a las predicciones correctas hechas por el modelo sobre el número total de predicciones.

$$\text{Exactitud: } \frac{TP+TN}{TP+TN+FP+FN}$$

Sensibilidad (Recall). Esta métrica describe la proporción de nuestro modelo para identificar casos positivos. Se comparan las etiquetas identificadas como verdaderos FN sobre el total de verdaderos positivos TP, como se puede apreciar en la ecuación.

$$\text{Sensibilidad} = \frac{TP}{TP+FN}$$

Especificidad. Esta métrica describe la probabilidad de que un paciente sano tenga un resultado negativo en la prueba. Se comparan las etiquetas identificadas como verdaderos negativos *TN* y los falsos positivos *FP*, como se aprecia en la ecuación.


$$\text{Especificidad} = \frac{TN}{TN+FP}$$

Matriz de confusión.

Es una herramienta que nos permite visualizar o evaluar el comportamiento del modelo que estamos entrenando de una forma más intuitiva, ya que nos permite tener tener la visualización del desempeño del modelo diferenciando los éxitos positivos y negativos, además de los falsos positivos y los falsos negativos que nos facilita la lectura de los

resultados. La dimensión es $n \times m$, con $n = m$, donde n representa la clase observada y m , la clase predicha.

Figura 20 Matriz de confusión.



Fuente: Propia

5.4 Diseño de Prototipo

El modelo de desarrollo que se escogió fue el prototipado evolutivo ya que es un modelo de diseño rápido, de continuos cambios, sin embargo, por razones de la pandemia, no se pudo tener un contacto o retroalimentación con un Radiólogo. Se procedió a definir los requerimientos funcionales y no funcionales los cuales están descritos en la siguiente tabla:

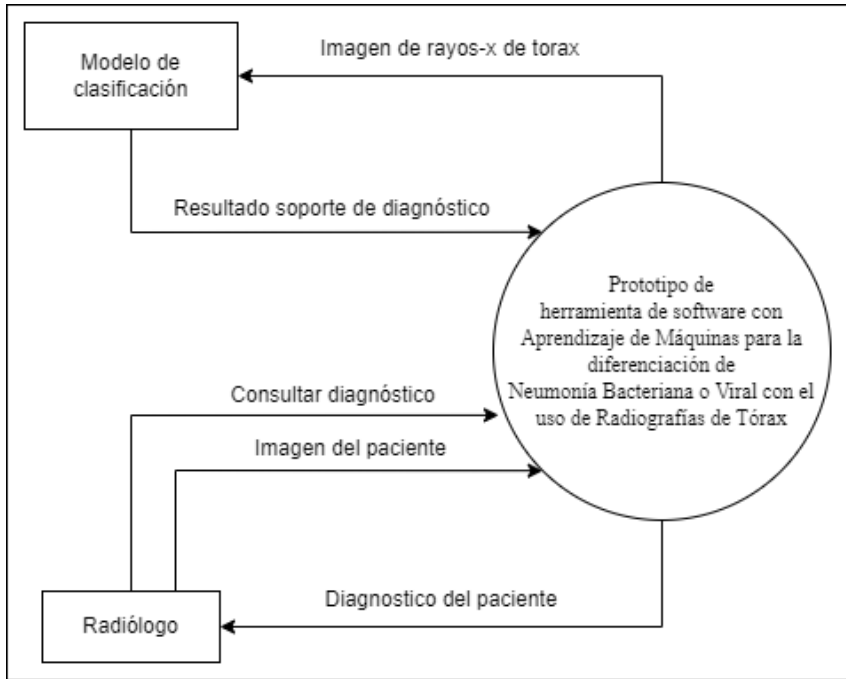
Tabla 3 Requerimientos funcionales y no funcionales

Requerimientos No Funcional	<ul style="list-style-type: none"> -La herramienta debe poder conectarse con el repositorio del modelo. -La herramienta debe de estar disponible en Windows sin tener instalado Matlab.
Requerimientos Funcionales	<ul style="list-style-type: none"> -El usuario debe poder ejecutar la herramienta. -El usuario debe poder cargar una imagen en la herramienta. -El usuario debe poder abrir la imagen previamente cargada en una ventana. -La herramienta debe poder clasificar la imagen. -La herramienta debe mostrar un gráfico de análisis de componentes principales.

Diagramas UML

Para tener una claridad en la implementación del prototipo se utilizó el lenguaje UML para modelar los requerimientos y funcionalidades, mediante los diagramas de casos de uso, y de clases.

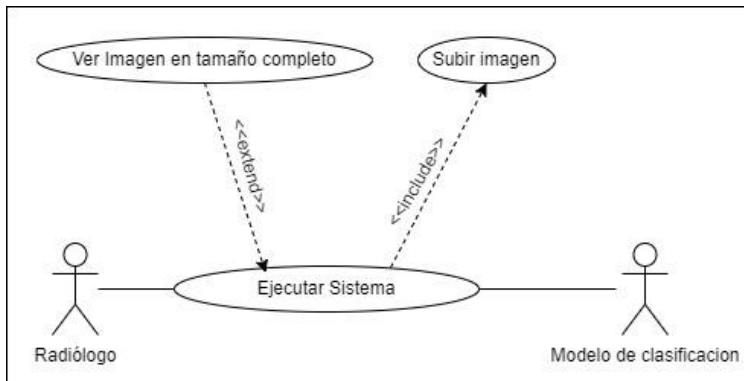
Figura 21 Diagrama de contexto



Fuente: Propia
Casos de Uso

El diagrama de casos de uso representa la manera en que se relacionan los actores con las funcionalidades del sistema.

Figura 22 Diagrama de casos de uso



Fuente: Propia

6. Resultados

6.1. Selección de la Infraestructura Tecnológica


6.1.1. Prueba de Lenguajes Enfocados en Deep learning.

Para poder hallar el lenguaje de programación más adecuado y preciso se realizó un entrenamiento utilizando la red VGG 16 en los dos lenguajes de programación más utilizados para el deep learning: Matlab y Python. Se entrenaron con la misma base de datos y las mismas configuraciones de su entorno: ritmo de aprendizaje, el mismo número de épocas, y tamaño de grupo de imágenes, para así, poder hacer una comparativa de sus resultados.

Prueba #1

Juntamos el grupo de normal con el de bacteriana para ver la capacidad de la red neuronal para diferenciar a las personas que padecen neumonía viral de las demás clases.


Figura 23 Comparación Matlab vs Python Metaclass Norm+Bac vs Virus



Fuente: Propia

Prueba #2

Figura 24 Comparación Matlab vs Python Metaclass Enfermo vs Normal

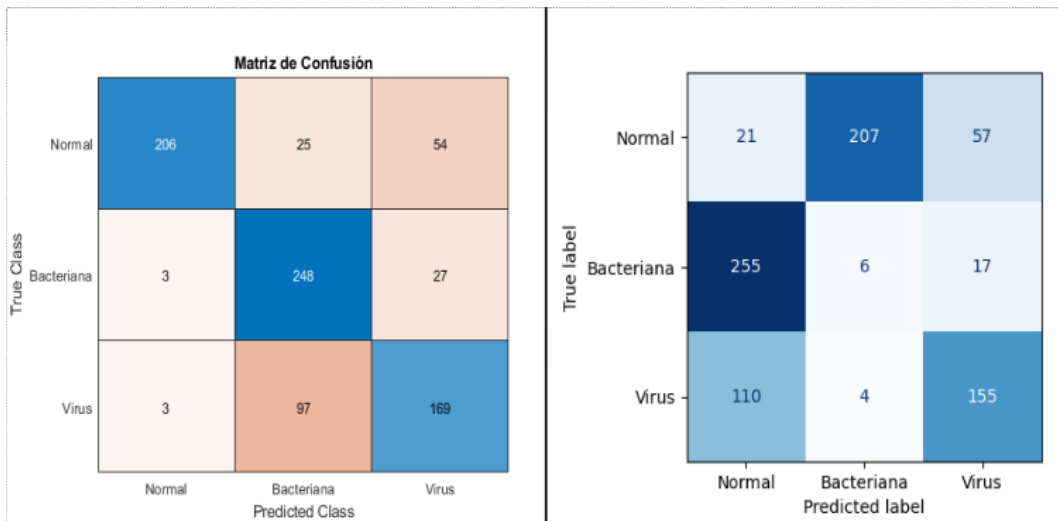


Fuente: Propia

Podemos ver una gran diferencia entre Python y Matlab, con una gran diferencia en la precisión, sensibilidad y especificidad de los modelos. Donde podemos apreciar la superioridad del modelo que fue entrenado en Matlab.

Prueba #3

Figura 25 Comparación tres clases Matlab vs Python



Fuente: Propia

En la diagonal principal de cada una de las matrices de confusión podemos ver apreciar la precisión de nuestro modelo, además de la gran diferencia que existe entre el modelo entrenando en Python y el modelo entrenado en Matlab, en la siguiente tabla se comparan las métricas de evaluación usadas para definir el lenguaje del modelo.

Tabla 4 Tabla de comparación de entrenamientos de VGG16.

	Matlab VGG16	Python VGG16
Tiempo de Entrenamiento	288.3 mn(4,8 horas)	18,56 mn
Precisión (Normal+Bacteriana)	0,78	0,77
Sensibilidad (Normal+Bacteriana)	0,63	0,58
Especificidad (Normal+Bacteriana)	0,86	0,87
Precisión (Enfermo vs Normal)	0,90	0,24
Sensibilidad (Enfermo vs Normal)	0,99	0,33
Especificidad (Enfermo vs Normal)	0,72	0,98
Precisión de las 3 clases	0,75	0,22

Fuente: Propia

Habiendo analizado los resultados de las métricas de los dos modelos podemos concluir que el mejor lenguaje para hacer el desarrollo del modelo de clasificación es Matlab, ya que tiene una precisión, sensibilidad y especificidad mayores al modelo de Python.

Pese que el modelo de Python tiene un tiempo de entrenamiento muy reducido, no se ve la ventaja en la clasificación, además de que la brecha diferenciadora entre los dos lenguajes es

muy amplia, sumando el hecho de que Python tiene una mayor dificultad en su configuración para poder instalar librerías que sean compatibles, haciendo que el tiempo que se gana con el bajo tiempo de entrenamiento se tenga que invertir corrigiendo errores, o buscando soluciones que permitan su buen funcionamiento.

Se presenta en forma exacta el aporte del desarrollo del trabajo en concordancia a la justificación presentada. Se describen en forma lógica, los resultados del trabajo, dando respuesta a los objetivos o propósitos planteados. Basado en los resultados recolectados, incluido el tratamiento estadístico o cualitativo. Se muestran en forma concisa los productos y/o resultados y se resaltan las contribuciones del trabajo al contexto local, regional, nacional e internacional, cuando aplique.

6.1.2. Arquitectura del Modelo

Se hizo el entrenamiento de las diferentes redes (Xception, Resnet-50, Vgg16), haciendo uso de la variación de los parámetros, empezando por el batch: 32/64, el ritmo de aprendizaje: 1,00E-1/ 1,00E-3/ 1,00E-6 y por último el algoritmo: Sgdm/Adam/Rmsprop

Tabla 5 Resultado de entrenamiento de las redes VGG-16, RESNET 50 y XCEPTION

#	Algoritmo	Bach	Tasa de Aprendizaje	Resultados de la precisión en validación		
				VGG-16	RESNET 50	XCEPTION
1	SGDM	32	1,00E-01	33,333	77,6	33,33
2			1,00E-03	33,333	90	89,20
3			1,00E-06	77,533	75,4667	57,07
4			1,00E-09	30,9667	31,5333	25,97
5	ADAM		1,00E-01	33,333	53,4333	60,60
6			1,00E-03	33,333	83,6333	87,53
7			1,00E-06	85,4333	84,5	79,63
8			1,00E-09	35,933	33,733	26,40
9	RMSPROP		1,00E-01	33,333	33,333	63,80
10			1,00E-03	33,333	83,533	87,97
11			1,00E-06	85,033	84,0667	80,27
12			1,00E-09	36	34,333	34,97
13	SGDM	64	1,00E-01	33,333	77,033	-

14			1,00E-03	33,333	89,2667	-
15			1,00E-06	76,0667	73,9333	-
16			1,00E-09	28,5667	31,5	-
17	ADAM		1,00E-01	33,3333	20,2333	-
18			1,00E-03	33,3333	86,2667	-
19			1,00E-06	83,8667	82,5	-
20			1,00E-09	32,9	32,533	-
21	RMSPROP		1,00E-01	33,333	47,8667	-
22			1,00E-03	33,333	85,4	-
23			1,00E-06	83,3	82,6	-
24			1,00E-09	32,8667	32,933	-

Fuente: Propia

Para la red Neuronal Xception solo se hizo la mitad de entrenamientos debido a su alto coste computacional.

De las redes con mejores resultados en los entrenamientos se procedió a hallar la especificidad y sensibilidad usando los dos conjuntos de test, el usado para el aumento de datos (Test 1) y el desconocido para el sistema (Test 2) así como está explicado en la siguiente tabla:

Tabla 6 Métricas de evaluación de las redes neuronales

Red	Sensitividad 1	Especificidad 1	Precisión 1	Sensitividad 2	Especificidad 2	Precisión 2
Vgg16	0,959	0,994	0,984	0,9676	0,7278	0,9237
Resnet50	0,968	0,999	0,9783	0,9701	0,8038	0,9289
Xception	0,965	0,999	0,9763	0,9809	0,8418	0,9428

Fuente:

Propia


De lo cual pudimos concluir que Xception sería la red elegida ya que era la que tenía mejores resultados respecto a la sensibilidad, (se desarrollaron los test con dos diferentes bases de datos de prueba).

6.1.3. Fscnca

Después de la reducción de dimensionalidad con Fscnca, se tuvo como resultado un gran número de componentes principales los cuales están representados en la siguiente figura:

Virus vs bacteriana vs normal


Figura 26 Grafica del proceso de reducción de dimensionalidad de las 3 clases



Fuente: Propia

Metaclase virus vs normal + bacteriana


Figura 27 Grafica del proceso de reducción de dimensionalidad metaclase Normal+Bacteriana



Fuente: Propia

Metaclase enfermo vs normal

Figura 28 Grafica del proceso de reducción de dimensionalidad metaclase Virus+Bacteriana vs Normal



Fuente: Propia

Se procedió a hacer uso del método del codo para poder reducir el número de componentes principales y tenerlos organizados respecto a su peso.

Sin embargo, ya que el método del codo está principalmente basado en la observación, se usó la fórmula de la energía de la señal para poder así tener un resultado más riguroso respecto a las características relevantes en nuestro modelo, cuya fórmula se describe a continuación:

$$\sum_{i=1}^n \|x^k\|^2 = \text{Energía}$$

Decidimos tomar el 90% de los datos que conformaban la energía total del modelo, que corresponden a los resultados de la siguiente tabla:

Tabla 7 Resultado de la energía de los modelos

Clases	Energía Total	# de Características al 90%
Virus vs Bacteriana vs Normal	20480073000	1844
Enfermo vs Normal	20470607000	1844
Viral vs Normal + Bacteriana	20479998000	1844

Fuente: Propia

Se tuvo que el número de características que corresponden al 90% para los 3 modelos fue de 1844 características.

6.1.4. Máquina de soporte vectorial:

Para la máquina de soporte vectorial, se hizo la sintonización de las características a través de las herramientas que nos ofrecía Matlab, pudiendo encontrar las mejores características dependiendo del algoritmo que se usara, por eso se hizo pruebas de sintonización automática con cada uno de los algoritmos disponibles, y también para los diferentes modelos de metaclasses, para posteriormente poderlos comparar, lo cual se resume en la siguiente tabla de comparaciones:

Tabla 8 Sintonización de las SVM respecto a las metaclasses

Modelo	Algoritmo		Precisión Test	Sensitividad	Especificidad
--------	-----------	--	----------------	--------------	---------------

		Precisión validación múltiple			
3 clases	Gauss	0,54	0,80	0,64	1,00
	RBF	0,47	0,74	55,60	0,85
	Lineal	0,97	0,94	0,64	1,00
	Polinomial	0,98	0,96	0,93	0,96
Normal vs Enfermo	Gauss	0,98	0,96	0,98	0,92
	RBF	0,98	0,96	0,98	0,93
	Lineal	0,98	0,94	0,97	0,88
	Polinomial	0,98	0,96	0,98	0,93
Virus vs Norm+ Bac	Gauss	97,88	92,57	0,85	0,96
	RBF	98,22	96,21	0,85	0,96
	Lineal	98,08	93,90	0,88	0,97
	Polinomial	98,23	96,23	0,93	0,98

Fuente: Propia.

El algoritmo polinomial fue el mejor resultado en promedio de las diferentes metaclases, siendo ese el elegido para el modelo final. Se procedió a realizar las pruebas con los dos conjuntos de validación al modelo final, representados por las siguientes matrices de confusión:

Figura 29 Matriz de confusión modelo final de la base de datos desconocida por el sistema

True Class	Bacteriana	241		37	86.7%	13.3%
	Normal		282	3	98.9%	1.1%
	Virus	12	4	253	94.1%	5.9%
		95.3%	98.6%	86.3%	4.7%	13.7%
		Bacteriana	Normal	Virus	Predicted Class	

Fuente: Propia.

El modelo final tuvo una precisión de 93%, con una sensibilidad de la clase virus de 94.1% y una especificidad de 83%, con el conjunto de test desconocido para el sistema.

Figura 30 Matriz de confusión modelo final de la base de datos con aumento de datos

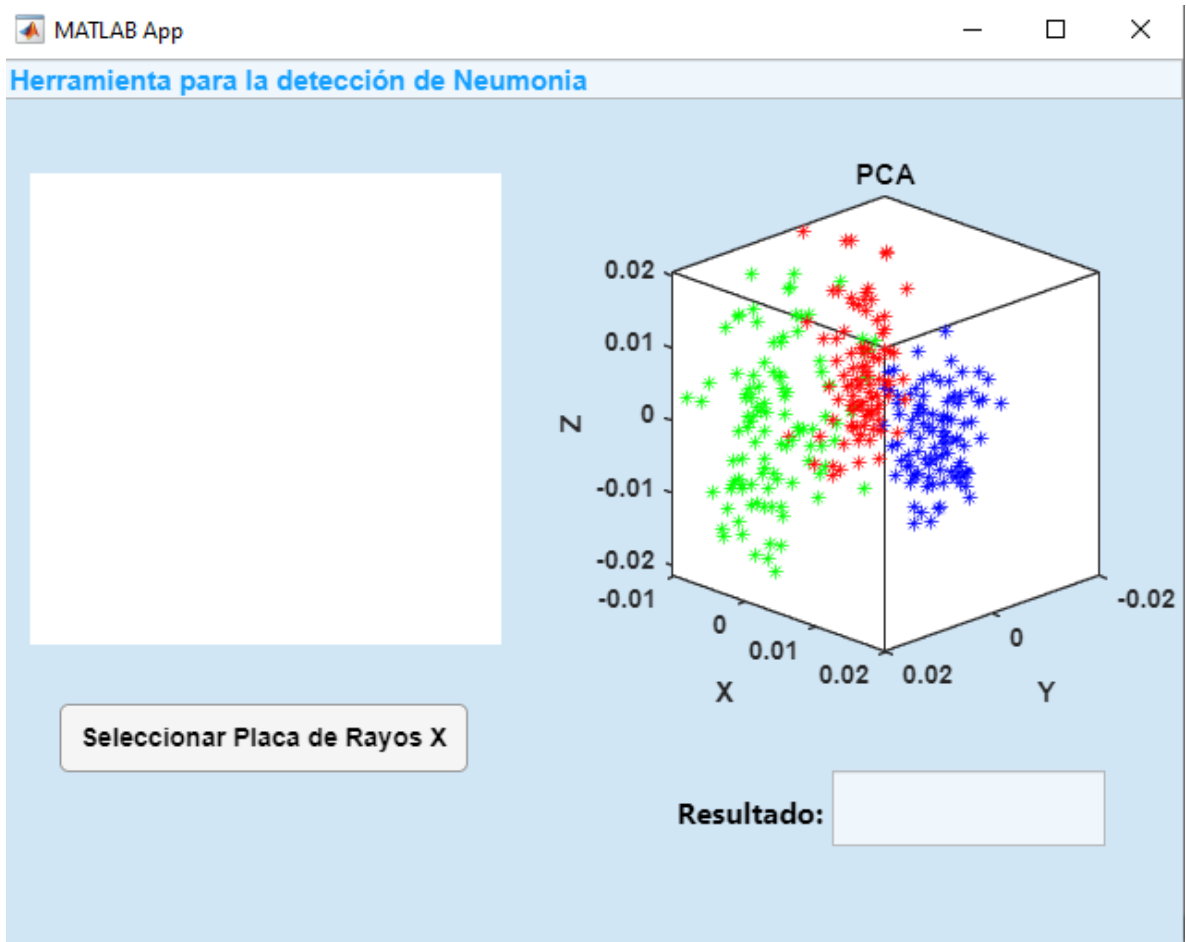
True Class	Bacteriana	884	24	92	88.4%	11.6%
	Normal		998	2	99.8%	0.2%
	Virus	25	19	956	95.6%	4.4%
		97.2%	95.9%	91.0%	2.8%	4.1%
						9.0%
		Bacteriana	Normal	Virus	Predicted Class	

El test con aumento de datos, se obtuvo una precisión de 94,6% con una sensibilidad del 95.6% y una especificidad del 91% para la clase virus.

6.2. Diseño del Prototipo.

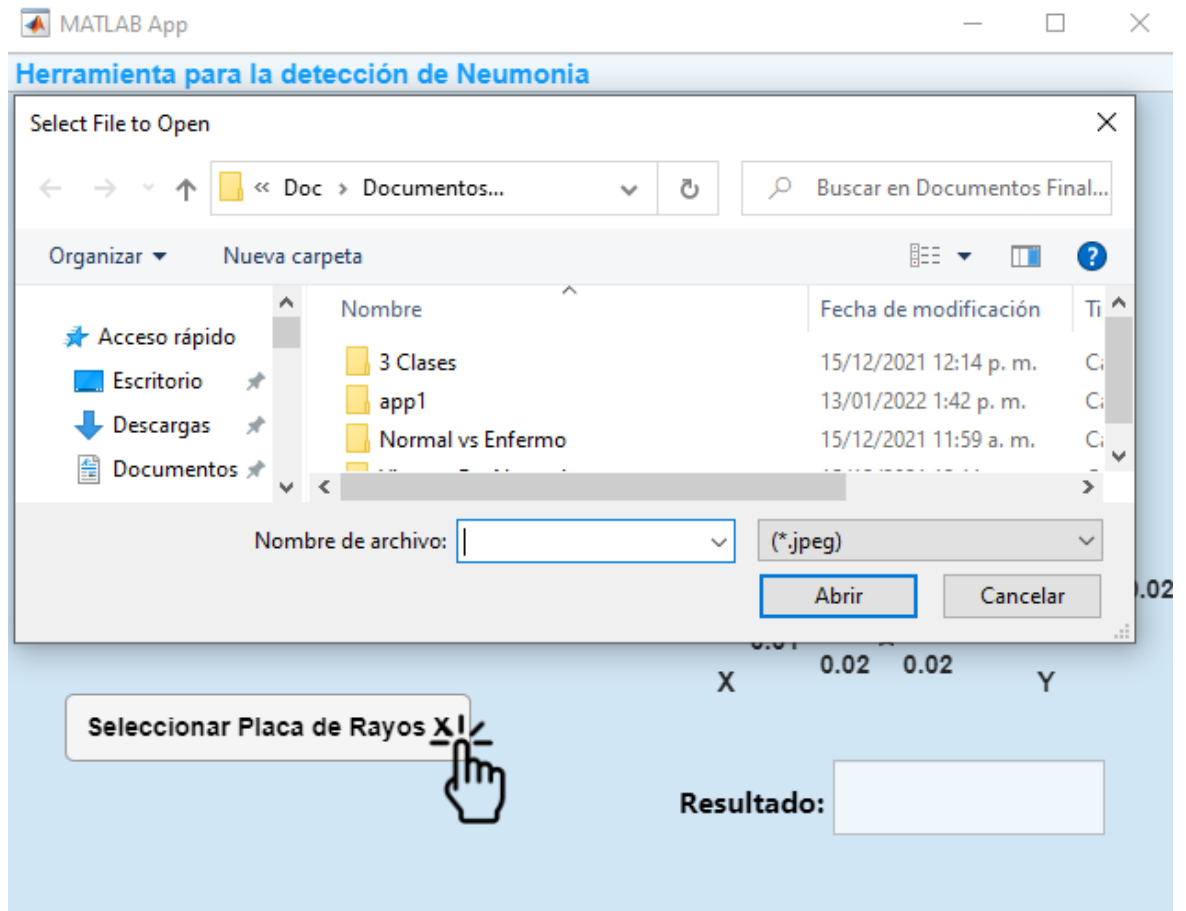
Ya habiendo definido las funcionalidades requeridas, se procedió al prototipado de la interfaz gráfica. Se enfocó en que la interfaz fuera funcional y que se cumpliera con las características para la correcta clasificación de las diferentes etiologías de neumonía pulmonar, además de brindarle al profesional una gráfica de análisis de componentes principales, así, incrementando la interpretabilidad, y dando una variable más para la clasificación como lo es la agrupación de los patrones respectivos de cada clase.

Figura 31 Interfaz gráfica en su página de inicio



Fuente: Propia

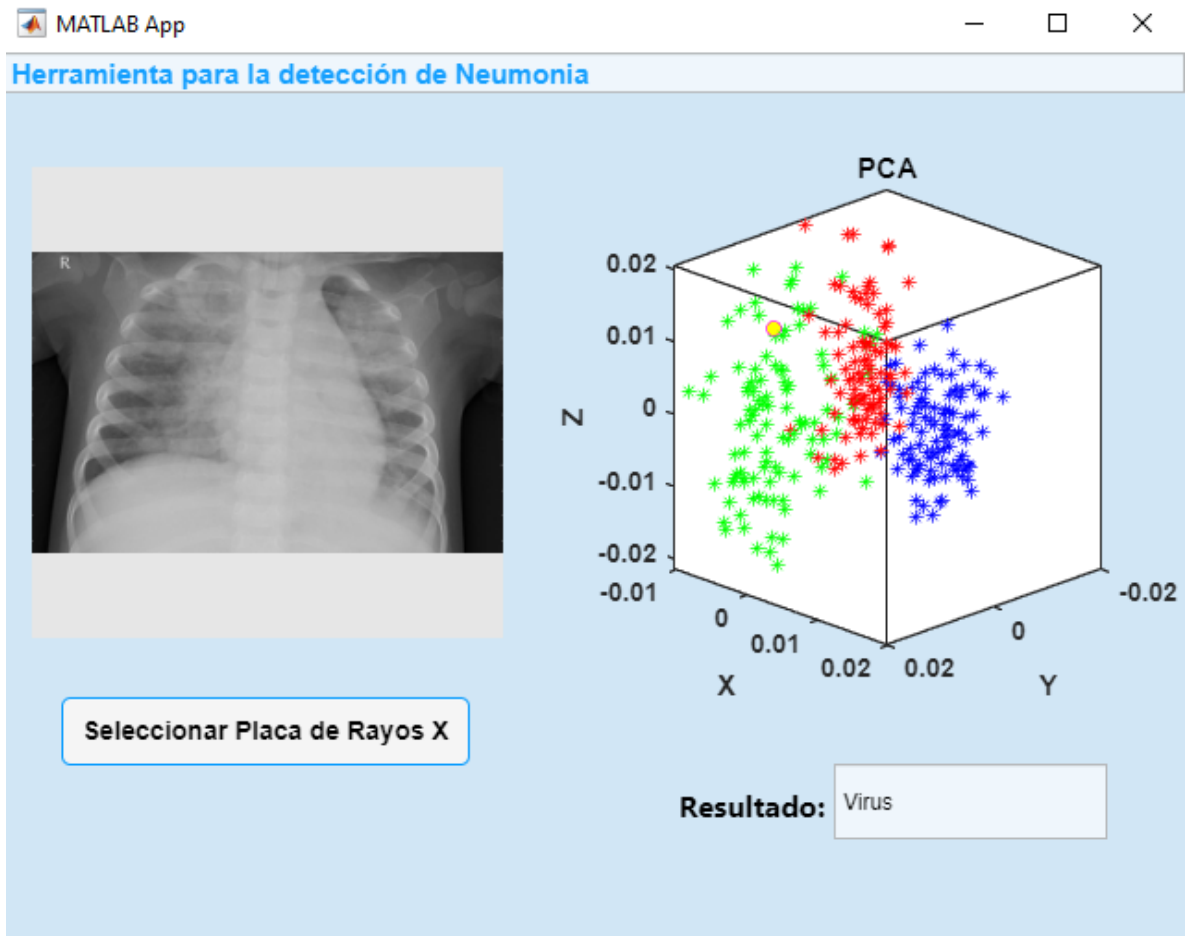
Figura 32 Interfaz gráfica selección de imagen de rayos x



Fuente: Propia

Una vez hecho clic en el botón de seleccionar placa de rayos x, se abrirá una ventana emergente que permitirá navegar por los archivos del computador y seleccionar una imagen de formato JPEG

Figura 33 Interfaz gráfica después de la clasificación



Fuente: Propia

Una vez seleccionada la imagen, se muestra una previa de la imagen de rayos-x y en consiguiente el resultado de la clasificación en la parte inferior en el cuadro de "Resultado", además se añade el resultado a la grafica de PCA donde se puede ver que esta marcada por un circulo amarillo con borde morado, para su fácil reconocimiento.

7. Conclusiones

Pese a que se pudo construir un sistema soporte de clasificación binario, el cual nos hubiera dado resultados incluso más precisos, se quiso utilizar un sistema que también proporcionara clasificación en cuyos casos se tratase de personas sin ninguna patología pulmonar, para así, poder agrupar todos los casos posibles relacionados con la neumonía.

Un diagnóstico en una etapa temprana de la enfermedad permite aplicar un tratamiento apropiado que contribuye a la recuperación del paciente, de esta manera ayudando a optimizar el trabajo de los radiólogos, y el personal médico y ayudando a esas zonas de Colombia donde se carecen de especialistas. Una de las características relevantes en la investigación fue la importancia del balanceo y aumento de datos, ya que cuando la problemática está relacionada al área de la salud, la disponibilidad de bases de datos, que tengan un nivel de confiabilidad alto, son escasas, por ende, el sobreajuste tiende a ser una problemática muy relevante a tener en cuenta. El acercamiento que se utilizó como solución fue la utilización de varios métodos de aumento de datos que estuviesen respaldados en otros trabajos similares, los cuales aportaran una mayor variabilidad para las clases con un menor número de datos, sin embargo, se llegó a la misma conclusión de varios trabajos similares, la precisión va estar directamente relacionada con la cantidad de datos aumentados, de forma que, entre mayor sea el número de aumento de datos, menor será la precisión, por ello se hizo uso de la máquina de soporte vectorial, la cual nos permitió hacer una agrupación y separación de las clases, de esta manera, incrementando la precisión del modelo de manera significativa.

8. Bibliografía

Amador-Gil, A., & Rico-Gala, S. (2013). Radiología de las fracturas: algo más que un trazo. *Radiología*, 215-224.

Bar, Y., Diamant, I., Wolf, L., Lieberman, S., Konen, E., & Greenspan, H. (2015). Chest pathology detection using deep learning with non-medical training. *Proceedings - International Symposium on Biomedical Imaging, 2015-July*, 294–297. <https://doi.org/10.1109/ISBI.2015.7163871>

Bartlett, J. G., Dowell, S. F., Mandell, L. A., File, T. M., Musher, D. M., & Fine, M. J. (n.d.). *Practice Guidelines for the Management of Community-Acquired Pneumonia in Adults*. <https://academic.oup.com/cid/article/31/2/347/293404>

Benítez, R., Escudero, G., Kanaan, S., & Rodó, D. M. (2014). Inteligencia artificial avanzada. Editorial UOC, S.L.
<https://books.google.com.co/books?id=eT7ABAAAQBAJ>

Betancourt, G. (2005). Las máquinas de soporte vectorial. *Sciencia et technica*, 67-72.

Bontrager, K. (2008). *Proyecciones radiológicas con correlación anatómica*. Madrid: Elsevier.

Botero, J., & Bedoya, E. (2010). Determinantes del diagnóstico periodontal. *Revista clínica de periodoncia, implantología y rehabilitación oral*, 94-99.

CDC. (20 de Diciembre de 2018). La radiación en medicina: procedimientos médicos por imágenes. Obtenido de Centro para el control y la prevención de enfermedades:
<https://www.cdc.gov/spanish/especialescdc/radiacionionizante/index.html>

Demler, O. V., Pencina, M. J., & D'Agostino, R. B. (2012). Misuse of DeLong test to compare AUCs for nested models. *Statistics in Medicine*, 31(23), 2577–2587. <https://doi.org/10.1002/sim.5328>

Ebell, M. H., Chupp, H., Cai, X., Bentivegna, M., & Kearney, M. (2020). Accuracy of Signs and Symptoms for the Diagnosis of Community-acquired Pneumonia: A Meta-analysis. *Academic Emergency Medicine*, 27(7), 541–553. <https://doi.org/10.1111/acem.13965>

Estacio, L. (2018). ELECCIÓN DE UN MÉTODO DE PROCESAMIENTO DE IMÁGENES DE RAYOS X, PARA EL SOPORTE DEL DIAGNÓSTICO DE LESIONES TRAUMATOLÓGICAS DE LA ESTRUCTURA PÉLVICA. Arequipa: Universidad Nacional San Agustín de Arequipa.

Forlino, D. (2006). *Semiología Radiológica Básica Cardiovascular del Tórax*. Obtenido de Cátedra de Diagnóstico de Imágenes:
<https://med.unne.edu.ar/sitio/multimedia/imagenes/ckfinder/files/files/7.->

[%20Semiologia%20Radiológica%20Básica%20Cardiovascular%20Torácica.pdf](#)

- Garnacho-Montero, J., García-Cabrera, E., Diaz-Martín, A., Lepe-Jiménez, J. A., Iraurgi-Arcarazo, P., Jiménez-Álvarez, R., Revuelto-Rey, J., & Aznar-Martín, J. (2010). Determinants of outcome in patients with bacteraemic pneumococcal pneumonia: Importance of early adequate treatment. *Scandinavian Journal of Infectious Diseases*, 42(3), 185–192.
<https://doi.org/10.3109/00365540903418522>
- Gil, R., Fernández, P., & Sabbagh, E. (2005). Diagnóstico clínico-radiológico de la neumonía del adulto adquirida en la comunidad. *Rev Chil Infect*, 26-31.
- González, A. (2007). *Los rayos X: Unas ondas centenarias en el diagnóstico médico*. Barcelona: Universitat de Barcelona.
- González, A. (2018). *Aplicaciones de técnicas de inteligencia artificial basadas en deep learning al análisis y mejora de procesos industriales*. Universidad de Oviedo: Oviedo.
- González, D. (2010). *Master de geotecnologías cartográficas en ingeniería y Arquitectura*. Obtenido de Universidad de Salamanca:
<https://gredos.usal.es/handle/10366/4910>
- Guyon, I., & De, A. M. (2003). An Introduction to Variable and Feature Selection André Elisseeff. In *Journal of Machine Learning Research* (Vol. 3).
- Hannah Ritchie (2019) - "Age Structure". Published online at OurWorldInData.org. Retrieved from: '<https://ourworldindata.org/age-structure>'
- Instituto Nacional del Cáncer. (26 de Noviembre de 2018). Significado de cambios y afecciones de los senos. Obtenido de Cáncer de Seno:
<https://www.cancer.gov/espanol/tipos/seno/significado-cambios-en-los-senos>
- J. Chen, L. Yang, Y. Zhang, M. Alber, and D. Z. Chen, “Combining fully convolutional and recurrent neural networks for 3D biomedical image segmentation,” in *Proc. Adv. Neural Inf. Process. Syst.*, 2016, pp. 3036–3044
- Jaiswal, A. K., Tiwari, P., Kumar, S., Gupta, D., Khanna, A., & Rodrigues, J. J. P. C. (2019). Identifying pneumonia in chest X-rays: A deep learning approach. *Measurement: Journal of the International Measurement Confederation*, 145, 511–518.
<https://doi.org/10.1016/j.measurement.2019.05.076>
- Ker, J., Wang, L., Rao, J., & Lim, T. (2017). Deep Learning Applications in Medical Image Analysis. *IEEE Access*, 6, 9375–9379.

<https://doi.org/10.1109/ACCESS.2017.2788044>Bar, Y., Diamant, I., Wolf, L., Lieberman, S., Konen, E., & Greenspan, H. (2015). Chest pathology detection using deep learning with non-medical training. *Proceedings - International Symposium on Biomedical Imaging, 2015-July*, 294–297. <https://doi.org/10.1109/ISBI.2015.7163871>

Kermany, D., Zhang, K., & Goldbaum, M. (2018). *Labeled Optical Coherence Tomography (OCT) and Chest X-Ray Images for Classification. 2.* <https://doi.org/10.17632/RSCBJBR9SJ.2>

Liang, G., & Zheng, L. (2020). A transfer learning method with deep residual network for pediatric pneumonia diagnosis. *Computer Methods and Programs in Biomedicine*, 187, 104964. <https://doi.org/10.1016/j.cmpb.2019.06.023>

Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. In *Medical Image Analysis* (Vol. 42, pp. 60–88). Elsevier B.V. <https://doi.org/10.1016/j.media.2017.07.005>

Sharma, A., Raju, D., & Ranjan, S. (2018). Detection of pneumonia clouds in chest X-ray using image processing approach. *2017 Nirma University International Conference on Engineering, NUiCONE 2017, 2018-Janua*, 1–4. <https://doi.org/10.1109/NUICONE.2017.8325607>

Mayo Clinic. (13 de Marzo de 2018). Diagnóstico de Neumonía. Obtenido de Enfermedades y Afecciones: <https://www.mayoclinic.org/es-es/diseases-conditions/pneumonia/diagnosis-treatment/drc-20354210>

Mischak, R., & Sciences, A. (2019). STUDY AND COMPARISON OF DIFFERENT DEEP LEARNING METHODS REFERING TO SKIN WOUND DETECTION A Master thesis by CHAIMAE KASSARA GUENNOUN. July.

Moberg, A. B., Taléus, U., Garvin, P., Fransson, S. G., & Falk, M. (2016). Community-acquired pneumonia in primary care: clinical assessment and the usability of chest radiography. *Scandinavian Journal of Primary Health Care*, 34(1), 21-27.

Moncada, D. C., Rueda, Z. V., Macías, A., Suárez, T., Ortega, H., & Vélez, L. A. (2011). Reading and interpretation of chest X-ray in adults with community-acquired pneumonia. *Brazilian Journal of Infectious Diseases*, 15(6), 540–546. [https://doi.org/10.1016/S1413-8670\(11\)70248-3](https://doi.org/10.1016/S1413-8670(11)70248-3)

Pasveer, B. (1989). Knowledge of shadows: the introduction of X-ray images in medicine. *Sociology of Health & Illness*, 11(4), 360–381. <https://doi.org/10.1111/1467-9566.ep11373066>

- Prasoon, A., Petersen, K., Igel, C., Lauze, F., Dam, E., & Nielsen, M. (2013). Deep feature learning for knee cartilage segmentation using a triplanar convolutional neural network. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 8150 LNCS(PART 2), 246–253. https://doi.org/10.1007/978-3-642-40763-5_31
- Raudales, R. (2014). Imágenes Diagnósticas: Conceptos y Generalidades. *Revista Facultad de Ciencias Médicas*, 35-43.
- Restrepo, A. (1998). Procesamiento de imágenes médicas. *Revista Universidad EAFIT*.
- Rodríguez, M., & Martínez, A. (Octubre de 1997). El uso de los rayos X en la medicina. Obtenido de Instituto de Física - UNAM: <http://www.smf.mx/boletin/Oct-95/ray-med.html>
- Roth, H. R., Lu, L., Seff, A., Cherry, K. M., Hoffman, J., Wang, S., Liu, J., Turkbey, E., & Summers, R. M. (2014). A new 2.5D representation for lymph node detection using random sets of deep convolutional neural network observations. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 8673 LNCS(PART 1), 520–527. https://doi.org/10.1007/978-3-319-10404-1_65
- Ruiz, C. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Rosario: Universidad Nacional.
- Sociedad de Radiología Americana. (13 de Mayo de 2016). Tomografía axial computarizada. Obtenido de Radiology for Patients: <https://www.radiologyinfo.org/sp/submenu.cfm?pg=ctScan>
- Soofi, A., & Awan, A. (2017). Classification Techniques in Machine Learning: Applications and Issues. *Journal of Basic & Applied Sciences*, 13(August), 459–465. <https://doi.org/10.6000/1927-5129.2017.13.76>
- Stark, G. (2020, January 30). *Bremsstrahlung | physics | Britannica*. <https://www.britannica.com/science/bremsstrahlung>
- Stephen, O., Sain, M., Maduh, U. J., & Jeong, D. U. (2019). An Efficient Deep Learning Approach to Pneumonia Classification in Healthcare. *Journal of Healthcare Engineering*, 2019. <https://doi.org/10.1155/2019/4180949>
- Stollenga, M. F., Byeon, W., Liwicki, M., & Schmidhuber, J. (2015). *Parallel Multi-Dimensional LSTM, With Application to Fast Biomedical Volumetric Image Segmentation*.
- Tran, B. X., Vu, G. T., Ha, G. H., Vuong, Q.-H., Ho, M.-T., Vuong, T.-T., La, V.-P., Ho, M.-T., Nghiem, K.-C. P., Nguyen, H. L. T., et al. (2019). Global

evolution of research in artificial intelligence in health and medicine: A bibliometric study. *Journal of clinical medicine*, 8(3):360.

Musić, J., WSEAS (Organization), WSEAS International Conference on Computer Engineering and Applications (8th : 2014 : Tenerife, C. I., International Conference on Applied Informatics and Computing Theory (5th : 2014 : Tenerife, C. I., & International Conference on Communications and Information Technology (8th : 2014 : Tenerife, C. I. (n.d.). Recent advances in computer engineering, communications and information technology : proceedings of the 8th WSEAS international conference on computer engineering and applications (CEA '14), proceedings of the 5th international conference on applied informatics and computing theory (AICT '14), proceedings of the 8th international conference on communications and information technology (CIT '14) : Tenerife, Spain, January 10-12, 2014. 427.

Universidad Politécnica de Catalunya. (2015). Aprendizaje Automático. Obtenido de Módulo de Aprendizaje IA:

<https://www.cs.upc.edu/~bejar/ia/transpas/teoria/6-AP-aprendizaje.pdf>

Wang, G., Li, W., Zuluaga, M. A., Pratt, R., Patel, P. A., Aertsen, M., Doel, T., David, A. L., Deprest, J., Ourselin, S., Vercauteren, T., Wang, G., Li, W., Pratt, R., Patel, P. A., Doel, T., Ourselin, S., Zuluaga, M. A., & David, A. L. (2018). Interactive Medical Image Segmentation Using Deep Learning With Image-Specific Fine Tuning. *IEEE TRANSACTIONS ON MEDICAL IMAGING*, 37(7). <https://doi.org/10.1109/TMI.2018.2791721>

World Health Organization. (2019). Pneumonia. <https://www.who.int/news-room/fact-sheets/detail/pneumonia>

Zech, J. R., 1, I. D., Badgeley, M. A., 2, I. D., Liu Id, M., Id, A. B. C., Titano, J. J., & Oermannid, E. K. (2018). Variable generalization performance of a deep learning model to detect pneumonia in chest radiographs: A cross-sectional study. <https://doi.org/10.1371/journal.pmed.1002683>

ANEXOS

Anexo 1 Tabla de Resultados Redes Neuronales

Para la selección de la red neuronal se llevaron a cabo pruebas utilizando diferentes parámetros de entrenamiento. El resultado se muestra a continuación

TABLA DE RESULTADOS XCEPTION									
#	Tiempo de Entrenamiento	Ritmo de Aprendizaje	Epocas	Algoritmo	Batch	Precisión de Entrenamiento	Perdida en Entrenamiento	Precisión en Validación	Perdida en Validación
1	9 hr 13 mn 35 seg	1,00E-01	25	sgdm	32	40,63	1,26	33,33	1,33
2	9 hr 15 mn 40 seg	1,00E-03	25	sgdm	32	100,00	0,01	89,20	0,52
3	9 hr 16 mn 40 seg	1,00E-06	25	sgdm	32	62,50	0,94	57,07	0,97
4	9 hr 19 mn 37 seg	1,00E-09	25	sgdm	32	31,25	1,13	25,97	1,14
5	9 hr 23 mn 00 seg	1,00E-01	25	adam	32	53,13	0,71	60,60	0,74
6	9 hr 23 mn 46 seg	1,00E-03	25	adam	32	93,75	0,10	87,53	0,43
7	9 hr 21 mn 44 seg	1,00E-06	25	adam	32	93,75	0,27	79,63	0,48
8	9 hr 24 mn 12 seg	1,00E-09	25	adam	32	28,13	1,13	26,40	1,14
9	11 hr 25 mn 15 seg	1,00E-01	25	rmsprop	32	78,13	1,06	63,80	1,36
10	11 hr 38 mn 34 seg	1,00E-03	25	rmsprop	32	96,88	0,11	87,97	0,50
11	11 hr 43 mn 25 seg	1,00E-06	25	rmsprop	32	78,13	0,36	80,27	0,47
12	11 hr 39 mn 27 seg	1,00E-09	25	rmsprop	32	37,50	1,11	34,97	1,11

TABLA DE RESULTADOS RESNET-50									
#	Tiempo de Entrenamiento	Ritmo de Aprendizaje	Epocas	Algoritmo	Batch	Precisión de Entrenamiento	Perdida en Entrenamiento	Precisión de Validación	Perdida en Validación
1	2 hr 39 mn 29 seg	1,00E-01	50	sgdm	32	87,5	0,2726	77,6	0,5232
2	2 hr 39 mn 46 seg	1,00E-03	50	sgdm	32	100	0,003	90	0,6116
3	2 hr 40 mn 51 seg	1,00E-06	50	sgdm	32	90,625	0,4957	75,4667	0,5638
4	2 hr 41 mn 06 seg	1,00E-09	50	sgdm	32	40,625	1,2514	31,5333	1,2316
5	3 hr 11 mn 16 seg	1,00E-01	50	adam	32	40,625	1,2195	53,4333	1,0362
6	3 hr 12 mn 53 seg	1,00E-03	50	adam	32	96,875	0,0697	83,6333	0,53
7	3 hr 14 mn 08 seg	1,00E-06	50	adam	32	96,875	0,0993	84,5	0,4594
8	3 hr 15 mn 17 seg	1,00E-09	50	adam	32	40,625	1,2174	33,733	1,1984
9	3 hr 01 mn 12 seg	1,00E-01	50	rmsprop	32	43,75	4,556	33,333	9,0507
10	3 hr 02 mn 13 seg	1,00E-03	50	rmsprop	32	100	0,833	83,533	0,5284
11	3 hr 02 mn 41 seg	1,00E-06	50	rmsprop	32	96,875	0,1074	84,0667	0,4758
12	3 hr 03 mn 12 seg	1,00E-09	50	rmsprop	32	40,625	1,2081	34,333	1,1899
13	2 hr 32 mn 51 seg	1,00E-01	50	sgdm	64	79,687	0,4856	77,033	0,5668
14	2 hr 33 mn 33 seg	1,00E-03	50	sgdm	64	100	0,0014	89,2667	0,6643
15	2 hr 34 mn 30 seg	1,00E-06	50	sgdm	64	71,875	0,6139	73,9333	0,6154
16	2 hr 35 mn 08 seg	1,00E-09	50	sgdm	64	34,375	1,2424	31,5	1,2396
17	2 hr 54 mn 14 seg	1,00E-01	50	adam	64	32,8125	3,4784	20,2333	2,4009
18	2 hr 55 mn 37 seg	1,00E-03	50	adam	64	89,0625	0,2123	86,2667	0,5422
19	2 hr 56 mn 11 seg	1,00E-06	50	adam	64	89,0625	0,2192	82,5	0,4657
20	2 hr 57 mn 23 seg	1,00E-09	50	adam	64	32,8125	1,2203	32,533	1,2158
21	2 hr 43 mn 38 seg	1,00E-01	50	rmsprop	64	37,5	9,4743	47,8667	4,057

22	2 hr 44 mn 38 seg	1,00E-03	50	rmsprop	64	90,625	0,2169	85,4	0,597
23	2 hr 45 mn 08 seg	1,00E-06	50	rmsprop	64	90,625	0,2238	82,6	0,471
24	2 hr 45 mn 13 seg	1,00E-09	50	rmsprop	64	32,8125	1,2159	32,933	1,211

TABLA DE RESULTADOS VGG16									
#	Tiempo de Entrenamiento	Ritmo de Aprendizaje	Epocas	Algoritmo	Batch	Precisión de Entrenamiento	Perdida en Entrenamiento	Precisión de Validación	Perdida en Validación
1	3 hr 12 mn 28 seg	1,00E-01	50	sgdm	32	25	NaN	33,333	NaN
2	3 hr 18 mn 16 seg	1,00E-03	50	sgdm	32	25	NaN	33,333	NaN
3	3 hr 21 mn 43 seg	1,00E-06	50	sgdm	32	84,375	0,3637	77,533	0,5186
4	3 hr 21 mn 31 seg	1,00E-09	50	sgdm	32	56,25	1,6897	30,9667	1,3753
5	4 hr 30 mn 14 seg	1,00E-01	50	adam	32	25	11,9568	33,333	10,6282
6	4 hr 34 mn 24 seg	1,00E-03	50	adam	32	34,375	1,1047	33,333	1,0992
7	4 hr 44 mn 14 seg	1,00E-06	50	adam	32	96,875	0,0949	85,4333	0,6117
8	4 hr 42 mn 30 seg	1,00E-09	50	adam	32	37,5	2,0457	35,933	1,2656
9	3 hr 49 mn 29 seg	1,00E-01	50	rmsprop	32	25	11,9568	33,333	10,6282
10	3 hr 51 mn 44 seg	1,00E-03	50	rmsprop	32	25	1,1047	33,333	1,0988
11	3 hr 47 mn 28 seg	1,00E-06	50	rmsprop	32	96,875	0,0817	85,033	0,6463
12	3 hr 50 mn 44 seg	1,00E-09	50	rmsprop	32	31,25	2,2103	36	1,2648
13	4 hr 05 mn 01 seg	1,00E-01	50	sgdm	64	35,9375	NaN	33,333	NaN
14	4 hr 07 mn 09 seg	1,00E-03	50	sgdm	64	34,375	1,0985	33,333	1,0987
15	4 hr 13 mn 58 seg	1,00E-06	50	sgdm	64	84,375	0,5007	76,0667	0,5449
16	4 hr 14 mn 16 seg	1,00E-09	50	sgdm	64	40,625	2,0755	28,5667	1,4413
17	5 hr 03 mn 27 seg	1,00E-01	50	adam	64	35,9375	10,2131	33,3333	10,6282


18	5 hr 15 mn 11 seg	1,00E-03	50	adam	64	34,375	1,0989	33,3333	1,0989
19	5 hr 17 mn 18 seg	1,00E-06	50	adam	64	98,4375	0,0652	83,8667	0,5453
20	5 hr 29 mn 40 seg	1,00E-09	50	adam	64	40,625	1,6815	32,9	1,337
21	3 hr 39 mn 57 seg	1,00E-01	50	rmsprop	64	35,9375	10,2131	33,333	10,6282
22	3 hr 40 mn 15 seg	1,00E-03	50	rmsprop	64	26,5625	1,1007	33,333	1,0988
23	3 hr 42 mn 42 seg	1,00E-06	50	rmsprop	64	98,4375	0,1018	83,3	0,6109
24	3 hr 49 mn 39 seg	1,00E-09	50	rmsprop	64	34,375	1,9704	32,8667	1,3324

Pruebas de la metaclassa Enfermo vs Normal para las redes con mejores resultados


Red	Sensitividad 1	Especificidad 1	Precisión 1	Sensitividad 2	Especificidad 2	Precisión 2
Vgg16	0,979	0,994	0,984	0,9976	0,7278	0,9237
Resnet50	0,968	0,999	0,9783	0,9701	0,8038	0,9289
Xception	0,965	0,999	0,9763	0,9809	0,8418	0,9428

Haciendo uso de el data set conocido por el modelo (Test 1) y el completamente desconocido por el sistema (Test 2), a continuación se dara una lista de matrices de confusión correspondientes a los diferentes test de cada una de las redes que corresponden a los resultados de la tabla superior.


Test 1 VGG-16




Test 2 VGG-16




Test 1 RESNET-50



Test 2 RESNET-50



Test 1 XCEPTION



Test 2 XCEPTION

