



BENEMÉRITA UNIVERSIDAD AUTÓNOMA DE PUEBLA
FACULTAD DE CIENCIAS DE LA ELECTRÓNICA

MAESTRÍA EN INGENIERÍA ELECTRÓNICA,
OPCIÓN INSTRUMENTACIÓN ELECTRÓNICA

Tesis para obtener el grado de

MAESTRO EN INGENIERÍA ELECTRÓNICA

**Sistema para determinación de la probabilidad de presencia de
COVID-19 en imágenes radiográficas de tórax utilizando
técnicas de aprendizaje automático**

Presenta:

Lic. Ángel Ernesto Picazo Castillo*

Directores

Dr. Salvador Eugenio Ayala Raggi

Dr. Aldrin Barreto Flores

*Becario CONACYT

Puebla, Pue., Noviembre 2023

Reflexiones

"Nada en la vida es para ser temido, es sólo para ser comprendido. Ahora es el momento de entender más, de modo que podamos temer menos".

-Marie Curie (1867-1934)

"La ciencia no conoce de países porque el conocimiento le pertenece a la humanidad, y es la antorcha que ilumina al mundo. La ciencia es el alma de la prosperidad de las naciones y la fuente de todo progreso"

-Louis Pasteur (1822-1895)

Después de todo, ¿qué es un científico entonces? Es un hombre curioso que mira a través del ojo de una cerradura, la cerradura de la naturaleza, tratando de saber qué es lo que sucede.

-Jacques Yves Cousteau (1910-1997)

Agradecimientos

A la Benemérita Universidad Autónoma de Puebla por haber sido mi segunda casa por 11 años y enriquecer mi vida con conocimiento, valores, experiencias invaluablees y personas que siempre llevo en mi corazón.

A la Facultad de Ciencias de la Electrónica, agradezco su orientación en el mundo de la ciencia, así como el espacio que proporcionó para vivir experiencias inolvidables y conocer a personas realmente admirables.

A CONACHYT por la beca otorgada durante los dos años de duración de la maestría.

A CONCYTEP por el apoyo otorgado.

Dedicatoria

Mi profundo agradecimiento y amor a mis padres María de los Ángeles Pilar Castillo Coeto y Ernesto Sebastián Picazo Hernández por sus grandes enseñanzas y por ser la fuente inagotable de amor, apoyo y guía en cada paso de mi vida. Su inquebrantable dedicación y valores han sido la brújula que ha orientado mi camino. Gracias por ser mis mayores inspiraciones y por siempre creer en mí, incluso en los momentos más desafiantes. A ustedes dedico con todo mi corazón este logro, que es también el suyo.

A mi madre por ser el Pilar fundamental de mi vida, por tu motivación y apoyo en los momentos más oscuros y en los momentos más alegres de mi vida, tu presencia ha sido mi mayor fortaleza. Tus palabras alentadoras y tu amor incondicional han sido la luz que ha iluminado mi camino. Agradezco tu paciencia infinita, tu sabiduría y la forma en que siempre encuentras la manera de hacerme sentir amado y respaldado. Este logro no solo es mío, sino también tuyo, y lo dedico con profundo agradecimiento por ser la increíble madre que eres.

A mi familia, cimiento sólido de amor y apoyo, quienes han sido mi refugio en cada adversidad y mi fuente de alegría en muchos triunfos. Su respaldo y cariño han sido motivación y admiración que han guiado mi trayectoria académica y personal.

A mis respetados asesores, Dr. Salvador E. Ayala Raggi y Dr. Aldrin Barreto Flores, cuyas mentes brillantes y orientación sabia han sido la luz que ilumina mi camino académico. Agradezco su paciencia, dedicación y la invaluable sabiduría que compartieron conmigo durante todo el tiempo de la maestría.

A la coordinadora M.C. Ana María Rodríguez Domínguez y maestros de la maestría, quienes con su compromiso y entrega han contribuido significativamente a mi formación. Su pasión por la enseñanza ha dejado una huella indeleble en mi corazón y mi aprendizaje.

A los maestros que me guiaron durante mi licenciatura, sembrando las semillas del conocimiento que hoy florecen. Su influencia perdura, y les agradezco por su

contribución a mi desarrollo académico.

A mis respetados sinodales, M.C. José Francisco Portillo Robledo, M.C Selene Edith Maya Rueda y M.C. Nicolas Quiroz Hernández, por sus críticas constructivas que han enriquecido mi trabajo y me han impulsado a alcanzar estándares de calidad más elevados en la investigación y la ciencia. Aprecio profundamente su tiempo y esfuerzo dedicados a evaluarme.

A mis compañeros y amigos de la maestría, quienes han compartido risas, desafíos y momentos inolvidables. Su apoyo y camaradería han sido un regalo invaluable que ha hecho este viaje más significativo y que recordaré por siempre.

A mí mismo, por la perseverancia, el esfuerzo y el compromiso. Este logro es el resultado de mi dedicación y determinación. Aquí estoy, celebrando un hito que representa no solo mi éxito, sino el triunfo conjunto de aquellos que han sido parte fundamental de mi viaje.

Resumen

En este trabajo de tesis se presenta un método para el reconocimiento de *COVID-19* basado en la localización automática y posterior normalización de la región de interés, en este caso, los pulmones, en radiografías de tórax.

El algoritmo usado y propuesto fue el Algoritmo Localizador de Pulmones que funciona mediante *PCA* y regresión ponderada *K-NN*. Nuestra técnica propuesta implica estimar las posiciones de las esquinas de la región de interés mediante interpolación y luego mapear la imagen dentro de esa región ubicada a una plantilla estandarizada de tamaño fijo.

El objetivo es hacer que todas las imágenes de entrenamiento en un conjunto de datos sean similares en términos de posición, ángulo de inclinación, escala y contraste, es decir, alinearlas.

Posteriormente, se utiliza el método de *Eigenfaces* para obtener un conjunto reducido de características principales que representan las imágenes normalizadas. A partir de estas características derivadas de *PCA*, se seleccionan aquellas con la mejor capacidad discriminatoria entre las clases mediante el criterio de Fisher (FR).

Nuestros resultados muestran que la combinación de nuestra técnica de alineación de la región pulmonar con la adecuada selección y ponderación de las características más discriminantes es suficiente para lograr una precisión máxima del 95.2% y 97% en la clasificación de radiografías de *COVID-19* cuando se utilizan clasificadores tradicionales como *K-NN* ponderado y *MLP*, respectivamente.

Nuestros resultados demuestran que nuestra técnica puede utilizarse para obtener resultados de clasificación similares o superiores a los logrados por las *CNNs*. Además de que nuestra metodología requiere un menor tiempo de entrenamiento

Lista de acrónimos

ROI Region of Interest (Región de Interés).

PCA Principal Component Analysis (Análisis de componentes principales).

ALP Algoritmo Localizador de Pulmones.

K-NN K-Nearest Neighbors (K-vecinos más cercanos).

MLP Multi Layer Perceptron (Perceptrón multi capa).

CNN Convolutional Neural Network (Red neuronal convolucional).

FR Fisher Ratio (Razón de Fisher).

Índice General

Reflexiones	I
Agradecimientos	II
Dedicatoria	III
Resumen	V
Lista de acrónimos	VI
Índice General	VI
Índice de Figuras	IX
Índice de Tablas	XII
1. Introducción	1
1.1. Trabajo Relacionado	2
1.2. Objetivos	4
1.2.1. Objetivo general	4
1.2.2. Objetivos específicos	4
1.3. Justificación	5
1.4. Descripción	6
1.4.1. Diagrama de bloques del sistema	7
1.5. Organización de la Tesis	9
2. Marco Teórico	10
2.1. Inteligencia Artificial	10
2.1.1. Aprendizaje de Máquina	11
2.1.2. Algoritmo K-NN (K-Nearest Neighbors)	12
2.1.3. Algoritmo Perceptrón Multicapa (Multilayer Perceptron)	15
2.1.4. Aprendizaje Profundo	17
2.2. Normalización de datos	19

2.3.	Métodos de Reducción de Dimensionalidad	20
2.3.1.	Análisis de Componentes Principales (PCA)	21
2.3.2.	Eigenfaces	23
2.4.	El Criterio de Fisher para la selección de características	26
2.4.1.	La razón de Fisher como ponderante para las características seleccionadas	29
2.5.	Histograma de una imagen en escala de grises	30
2.5.1.	Ecualización del Histograma	31
2.5.2.	CLAHE (Contrast Limited Adaptive Histogram Equalization) . . .	33
2.6.	Image Warping	34
3.	Desarrollo	36
3.1.	Estructura General	36
3.2.	Conjunto de imágenes radiográficas de tórax	37
3.3.	Mejora del contraste	38
3.4.	Ubicación de coordenadas	39
3.5.	Imágenes sintéticas para el aumento de datos	41
3.6.	Algoritmo Localizador de Pulmones (ALP)	43
3.6.1.	Etapa de entrenamiento del ALP	43
3.6.2.	Etapa de prueba del ALP	44
3.6.3.	Error y parámetros del ALP	46
3.6.4.	Extracción de la región de interés mediante la operación Warping .	46
3.7.	Aplicación de Eigenfaces	48
3.8.	Aplicación de la Selección de Características	48
3.9.	Aplicación de la Ponderación de Características	50
4.	Resultados	51
4.1.	Experimentos acerca de la selección y ponderación de características	51
4.1.1.	Resultados y discusiones para el K-NN ponderado	53
4.1.2.	Resultados y discusiones para el MLP	53
4.1.3.	Resultados y discusiones adicionales	54
4.2.	Construcción del MLP	55
4.3.	Interfaz de usuario	56
4.4.	Comparación con redes convolucionales	58
5.	Conclusiones y trabajo futuro	64
5.1.	Conclusiones	64
5.2.	Trabajo Futuro	65
	Bibliografía	66

Índice de Figuras

1.1.	Diagrama de bloques general del sistema.	7
1.2.	Diagrama de bloques de la etapa de entrenamiento.	7
1.3.	Diagrama de bloques de la ubicación pulmonar.	8
1.4.	Diagrama de bloques de la etapa de prueba.	8
2.1.	Representación gráfica del algoritmo K-NN.	14
2.2.	Topología básica de un MLP.	16
2.3.	Primera componente principal del conjunto de datos.	21
2.4.	Primera y segunda componente principal del conjunto de datos.	21
2.5.	La imagen reconstruida X (izquierda) se obtiene utilizando un vector columna de pesos llamado Ω para calcular una combinación lineal de las columnas (eigenfaces expresadas como vectores de columna) de la matriz Q (en el centro), más la imagen promedio (derecha).	25
2.6.	Ejemplo de distribuciones de frecuencia para cada clase. La capacidad discriminativa de una característica se puede evaluar visualmente mediante la separación entre los histogramas. El par de histogramas de la derecha muestra una mayor separación, lo que indica una mayor discriminación entre las clases. Por el contrario, el par de histogramas de la izquierda exhibe una menor discriminación.	26
2.7.	Representación gráfica del proceso de selección de características. Al calcular el FR para cada característica, se pueden seleccionar las características que mejor discriminan las clases y formar un subconjunto de características más pequeño y que mejor representan al conjunto de datos original.	28
2.8.	Representación gráfica del proceso de ponderación de características. Calculamos el valor ϱ_k para cada característica y luego normalizamos y ponderamos las características por su respectivo ϱ_k . De esta manera, cada característica tiene una importancia en el proceso de clasificación proporcional a su capacidad para discriminar clases.	29

2.9. Ejemplo de radiografía con su histograma sin procesar. Puede verse que hay valores de gris que no se están utilizando en el histograma. Además puede verse la función de distribución acumulada (FDA).	31
2.10. Ejemplo de radiografía con su histograma sin procesar y el resultado de la aplicación de la ecualización del histograma. Puede verse que el histograma se extiende en todos los valores de gris. Además puede verse el cambio en la función de distribución acumulada (FDA).	32
2.11. Ejemplo de radiografía con su histograma sin procesar y el resultado de la aplicación de CLAHE. Puede verse que en el histograma hay una mejor distribución de valores de gris en los píxel de la imagen. Además puede verse el cambio en la función de distribución acumulada (FDA).	34
2.12. Ejemplo de aplicación de <i>warping</i> a una imagen. Como resultado el as obtiene una nueva perspectiva y tamaño.	35
3.1. Diagrama general del sistema para las etapas de entrenamiento y prueba.	37
3.2. Ejemplos de imágenes de la base de datos de Kaggle.	38
3.3. Imagen original (derecha), ecualización del histograma(medio), CLAHE (derecha).	38
3.4. Arreglo de punto Q.	40
3.5. Secuencia de funcionamiento del "Algoritmo Etiquetador".	40
3.6. Elementos sintéticos con sus coordenadas de la ROI generados a partir de una imagen del conjunto de imágenes.	41
3.7. Secuencia de los procesos de entrenamiento y prueba del ALP.	43
3.8. Elemento de prueba original (derecha), puntos calculadas (medio), puntos reales (izquierda).	45
3.9. Vecinos más cercanos a la imagen de prueba.	45
3.10. Reconstrucción de la imagen de prueba mediante Eigenfaces.	46
3.11. Comparación de los arreglos de puntos Q_i y W_i . El proceso de obtención de los puntos W_i puede verse en el algoritmo 6.	47
3.12. Imagen de prueba con su zona de interés extraída.	48
3.13. Característica con el mayor poder discriminatorio de las clases.	49
3.14. Característica con el menor poder discriminatorio de las clases.	49
3.15. Proporción de la importancia de las características basándose en su poder discriminatorio de clases.	50
4.1. Descripción de los experimentos para las etapas de entrenamiento y prueba de los algoritmos K-NN y MLP.	52
4.2. Variación de características para el K-NN ponderado (azul) y el MLP (rojo).	54
4.3. Variación del número de neuronas para el MLP.	55

4.4. Variación de épocas el MLP.	55
4.5. Ventana principal de la interfaz de usuario.	57
4.6. Imagen clasificada como COVID-19 con probabilidad del 100%.	57
4.7. Imagen clasificada como Normal con probabilidad del 0%.	58
4.8. Imagen después de presionar <i>Mejorar Contraste</i>	58
4.9. Instrucciones en la ventana de ayuda.	59
4.10. Descripción del programa en Acerca de	59
4.11. . Secuencia de experimentos. En el primero, se lleva a cabo la clasificación sin ningún preprocesamiento para las radiografías. En el segundo, se procede a la normalización de las radiografías mediante el uso del ALP. En ambos experimentos, se realiza la clasificación utilizando CNNs y el clasificador propuesto.	60

Índice de Tablas

1.1. Trabajos que realizan detección de COVID-19 en radiografías de tórax aplicando CNNs.	3
1.2. Trabajos que realizan detección de COVID-19 en radiografías de tórax sin usar CNNs.	4
2.1. Técnicas de Aprendizaje, Ejemplos de Algoritmos, Características y Ventajas.	13
2.2. Algoritmos Importantes de Deep Learning y Sus Características	18
2.3. Pasos para la obtención de Eigenfaces	25
3.1. Parámetro K para el ALP	46
3.2. Valores J para el subconjunto de 10 características.	50
4.1. Resultado del K-NN ponderado para los experimentos	53
4.2. Resultados del MLP para los experimentos	54
4.3. Resultados del K-NN ponderado y MLP para la validación cruzada.	54
4.4. Resultados de precisión de las CNNs y el clasificador propuesto para los experimentos.	61
4.5. Tiempos de entrenamiento de las CNNs y el clasificador propuesto para los experimentos. (Horas:Min:Seg)	62
4.6. Número total de parámetros y número de parámetros entrenables para cada clasificador.	63

Capítulo 1

Introducción

La inteligencia artificial (IA) es un campo del conocimiento que busca emular la inteligencia humana utilizando robots o software para realizar acciones específicas. Su evolución e impacto en la vida cotidiana ha crecido significativamente gracias a los avances en hardware, como las unidades de procesamiento central (CPU) y las unidades de procesamiento gráfico (GPU), que permiten el procesamiento eficiente de grandes cantidades de datos mediante métodos matemáticos y computacionales [1].

Los algoritmos utilizados en IA se entrenan con conjuntos de datos y, posteriormente, son capaces de hacer predicciones basadas en la evidencia. La IA ha dejado su huella en todos los sectores comerciales y de la salud, brindando un alto nivel de asistencia a los usuarios y contribuyendo a la toma de decisiones informadas [2–5].

En el campo de la medicina, la IA se ha aplicado ampliamente en la detección y el diagnóstico asistido por computadora (CAD) mediante la evaluación de imágenes radiográficas utilizando diversos algoritmos de aprendizaje automático. La elección adecuada de un algoritmo en el ámbito médico es crucial, ya que afecta aspectos como el tiempo de procesamiento y la precisión de los pronósticos [6, 7].

La enfermedad COVID-19 ha desencadenado una pandemia global y ha cobrado la vida de más de 428 millones de personas en todo el mundo. En México, se han registrado más de 5.3 millones de casos y 313 mil muertes, según Our World in Data (2022) [8]. Por lo tanto, la detección oportuna de COVID-19 se ha vuelto crucial y representa un área potencial de aplicación para la IA [9, 10]. El uso de imágenes radiográficas permite un diagnóstico rápido y eficaz, ya que estas radiografías son accesibles, se entregan rápidamente y son altamente eficientes [11–13]. Esto contrasta con los diagnósticos mediante tomografías computarizadas [14, 15] o la técnica de reacción en cadena de la polimerasa de transcripción inversa (RT-PCR) [16, 17], que son más costosos y tienen una disponibilidad limitada a nivel mundial.

La detección de COVID-19 a través de radiografías de rayos X es realizada por profesionales de la salud altamente especializados, como radiólogos y técnicos en

radiología [18]. Sin embargo, debido al procesamiento de grandes volúmenes de datos e imágenes, emitir un diagnóstico oportuno y rápido puede resultar complicado, lo que a su vez dificulta la implementación de tratamientos eficaces de manera expedita [11–13]. Es importante destacar que las radiografías de diferentes bancos de imágenes pueden variar en términos de alineación, resolución y tamaño, lo cual tiene un impacto significativo en la precisión de las predicciones [7, 19]. Estos desafíos pueden abordarse y resolverse eficazmente mediante la aplicación adecuada de algoritmos de aprendizaje automático y visión por computadora.

En este trabajo de tesis, se propone diseñar e implementar algoritmos de aprendizaje automático para el preprocesamiento y normalización de las imágenes radiográficas, de manera que estas compartan características similares en cuanto a su posición, rotación y escala, es decir, se alineen adecuadamente. Además, se busca reducir y mejorar las características extraídas de las imágenes normalizadas, de modo que estas puedan ser utilizadas en clasificadores de aprendizaje automático para emitir predicciones sobre la presencia o ausencia de COVID-19 en los pacientes [11–14, 16–18].

1.1. Trabajo Relacionado

La inteligencia artificial ha tenido un impacto significativo en el campo de la medicina a través del diagnóstico asistido por computadora (CAD). Con la pandemia de SARS-COV-2 en curso, la IA ha logrado avances importantes en la lucha contra esta enfermedad. Por ejemplo, S. BisChoas desarrolló algoritmos para el diagnóstico temprano y el aislamiento de pacientes con COVID-19 [20].

La construcción de conjuntos de imágenes radiográficas de tórax se ha vuelto crucial para el desarrollo de algoritmos de aprendizaje automático capaces de reconocer el COVID-19 en radiografías. En la actualidad, existen diversas bases de datos públicas gracias a los esfuerzos conjuntos de diferentes institutos y hospitales [6, 21–23].

En cuanto a la clasificación de imágenes, la tendencia actual se inclina hacia el uso de redes neuronales convolucionales (CNNs), un método de aprendizaje profundo (deep learning) que ha logrado altos índices de precisión en conjuntos de datos específicos. Para evaluar los algoritmos de Machine Learning, se utiliza la precisión de la clasificación. Sin embargo, para realizar una mejor comparación entre los algoritmos, se debería utilizar el mismo conjunto de datos.

En la Tabla 1.1 se muestran diferentes trabajos basados en CNNs y sus respectivas precisiones en la clasificación [20, 21, 24–28].

Según [29], las arquitecturas utilizadas en los algoritmos basados en CNNs, como se muestra en la tabla 1.1, todavía enfrentan desafíos para lograr una clasificación confiable de la COVID-19, ya que su precisión tiende a disminuir al utilizar conjuntos de imágenes

Tabla 1.1: Trabajos que realizan detección de COVID-19 en radiografías de tórax aplicando CNNs.

Autores	Año	Precisión
S. Biswas. et al.	2021	93 %
K. Rangarajan. et al.	2021	92 %
C. Salvatore et al.	2021	97 %
A. Sharma. et al.	2020	93.75 %
Tsiknakis, N. et al.	2020	99 %
A. Abbas. et al.	2021	93.1 %
V. Ravi. et al.	2021	99.9 %

diferentes. Esto sugiere la posibilidad de explorar nuevas propuestas para la clasificación de radiografías que no dependan de redes neuronales convolucionales (CNN), como se discutió en un estudio anterior [30]. En dicho estudio, se utilizó una Red Neuronal Multicapa (MLP) y una arquitectura basada en la involución de imágenes. Esta última propone núcleos similares a los de las CNNs, pero comparte dinámicamente sus pesos en todas las dimensiones, lo que reduce la cantidad de multiplicaciones necesarias para los cálculos. Esta propuesta logró una precisión máxima de clasificación del 94.83 %.

Los trabajos de reconocimiento de COVID-19 en radiografías de tórax que no se basan en CNNs comparten similitudes en su metodología. En primer lugar, hacen uso de técnicas de preprocesamiento de imágenes, como se observa en [31–34], donde se emplean diversos tipos de filtros en las imágenes para reducir el ruido. Además, en [31, 32], se utilizan técnicas de mejora de contraste. Posteriormente, aplican técnicas para la reducción y selección de características de las imágenes que se utilizan en la etapa de preprocesamiento. Finalmente, proceden a la clasificación de las imágenes.

La tabla 1.2 proporciona una comparación de los diferentes trabajos relacionados junto con sus respectivas técnicas de preprocesamiento de imágenes, técnicas de extracción de características, algoritmo clasificador utilizado y porcentaje de precisión en la clasificación [31–35]. El algoritmo Support Vector Machine (SVM) muestra tener los mejores resultados, y en [32, 33], se obtienen resultados comparables al uso de CNNs.

Es importante destacar que los resultados obtenidos en este trabajo no tienen la intención de reemplazar a las CNNs en la clasificación de imágenes, sino más bien ofrecer una alternativa viable, como se ha demostrado en estudios anteriores, como los mencionados en [32, 33]. Esto muestra que la alineación de imágenes y una selección adecuada de características pueden producir resultados comparables a los algoritmos más ampliamente utilizados en el estado del arte, sin la necesidad de entrenar millones de parámetros. Cabe señalar que en la mayoría de los artículos revisados no se proporciona una interfaz que permita la ejecución de sus algoritmos. Esto es relevante, ya que sería beneficioso contar con una interfaz de usuario amigable que permita a los profesionales médicos emitir diagnósticos de manera más accesible.

Tabla 1.2: Trabajos que realizan detección de COVID-19 en radiografías de tórax sin usar CNNs.

Autores	Preprocesamiento de imágenes	Extracción de características	Clasificador	Precisión
Bazhdar et al., (2021)	Filtro Gaussiano, AHE	Patrón Binario Local	SVM	94.6 %
Prabhu et al., (2022)	Filtro de Mediana, HE	Histograma de Gradientes Orientados	SVM	97 %
Samsir et al., (2021)	Algoritmo Genético	Fusión de características	Naives Bayes	92.6 %
Akram et al., (2021)	Filtro de Mediana	PCA	MWOA-SSA	97 %
Kadry et al., (2020)	Filtro de Umbralización	Transformada Discreta de Ondas	SVM	89 %

1.2. Objetivos

1.2.1. Objetivo general

Desarrollar un conjunto de algoritmos de aprendizaje automático necesario para implementar un sistema capaz de determinar en forma automática la presencia de COVID-19 en imágenes radiográficas de tórax.

1.2.2. Objetivos específicos

1. Diseñar un algoritmo de alineación y recorte de imágenes radiográficas de tórax que normalice en traslación, escala y rotación las imágenes del conjunto de datos, tanto de entrenamiento como de evaluación.
2. Diseñar e implementar un método de reducción de dimensionalidad adecuado para las imágenes radiográficas de tórax.
3. Diseñar e implementar un algoritmo para la corrección de contraste en las imágenes radiográficas del conjunto de datos.
4. Diseñar e implementar un algoritmo para la extracción y selección de características que mejor discriminen las clases para nuestro conjunto de datos.
5. Diseñar e implementar una técnica de ponderación de características para mejorar su capacidad discriminativa para las clases y diseñar e implementar un algoritmo que realice esta función.

6. Seleccionar y evaluar uno de los algoritmos más usados de *Deep Learning* utilizando los mismos datos de entrenamiento usados en el sistema que se propone en esta tesis con el objetivo de comparar los resultados de clasificación.
7. Programar en *Python* los algoritmos propuestos para la detección de COVID-19, deberá contar con una interfaz de usuario.

1.3. Justificación

La pandemia global desatada por el SARS-CoV-2 ha mostrado la urgente necesidad de contar con una detección rápida y precisa de la COVID-19, incluso en un contexto en el que las vacunas están ampliamente disponibles. Una alternativa valiosa y económicamente viable para lograr un diagnóstico temprano reside en el análisis de radiografías de tórax, ya que no solo mejora la fiabilidad del diagnóstico, sino que también garantiza un tratamiento más efectivo para los pacientes [6, 7]. Sin embargo, este tipo de análisis es complejo y requiere de la experiencia de especialistas altamente capacitados para interpretar las imágenes con precisión [36].

En México, con una población que supera los 125 millones de habitantes, existen alrededor de cuatro mil radiólogos certificados por el Consejo Mexicano de Radiología e Imagen [37]. Esta disparidad refleja una falta de personal altamente cualificado para abordar la interpretación de radiografías. Cabe destacar que la habilidad del especialista y la calidad de las imágenes son factores determinantes que afectan la precisión del diagnóstico. Por lo tanto, el desarrollo de herramientas de apoyo desempeña un papel fundamental en la reducción de los tiempos de espera y la mejora de la atención médica [9].

La inteligencia artificial (IA) ha introducido soluciones valiosas para el procesamiento de grandes volúmenes de datos en diversos campos, incluida la medicina. La IA ha sido un aliado fundamental para los especialistas médicos, permitiendo una detección más temprana y precisa de enfermedades [2, 6, 7]. Este avance ha sido posible gracias a la disponibilidad de bases de datos médicas [6, 21–23], que han permitido el análisis de un mayor número de casos y, en consecuencia, una mayor confiabilidad en diversos contextos médicos.

Sin embargo, la variabilidad en la resolución, el tamaño y la alineación de las imágenes radiográficas en diferentes bases de datos puede afectar la eficacia de los algoritmos de IA cuando se prueban en conjuntos de datos distintos. Para abordar esto, muchos algoritmos aplican técnicas de mejora de imagen, como corrección de contraste o filtros, como se ha visto en estudios anteriores [31–35]. A pesar de estas mejoras, la variabilidad en la posición o rotación de la región pulmonar sigue siendo un desafío. Algunos han optado por el uso de redes neuronales convolucionales (CNNs) para clasificar las imágenes, ya

que estas redes son menos susceptibles a esta variabilidad [38]. Aunque eficaces, las CNNs pueden requerir tiempos de entrenamiento prolongados.

El objetivo central de esta propuesta de tesis de maestría es desarrollar algoritmos que aborden la normalización de las imágenes radiográficas de tórax, junto con la extracción y selección de características óptimas para la clasificación utilizando algoritmos tradicionales de aprendizaje automático. Se busca lograr resultados de clasificación que estén a la par o superen a los obtenidos con CNNs, y al mismo tiempo, reducir significativamente los tiempos de entrenamiento.

La implementación de estos algoritmos y la interfaz de usuario se llevará a cabo en Python, un lenguaje de programación de alto nivel, de código abierto y con bibliotecas en constante evolución. La interfaz será diseñada pensando en la facilidad de uso para los médicos, y el programa estará disponible sin necesidad de adquirir licencias, lo que facilitará su uso en radiología y hospitales.

1.4. Descripción

En este proyecto, se emplearon algoritmos tradicionales de aprendizaje automático para detectar la presencia de COVID-19 en imágenes radiográficas de tórax tomadas de bancos de imágenes públicos. Estas imágenes fueron sometidas a una serie de preprocesamientos, que incluyeron recorte, alineación y mejora de contraste, en conjunto conocidos como normalización. Como resultado de este proceso, se obtuvieron imágenes que presentaban una alta similitud entre ellas en términos de posición, rotación y escala.

Posteriormente, se llevó a cabo un proceso de mejora de características, que involucró la extracción y selección de aquellas características que tuvieron un mejor poder de discriminación entre las clases de interés. Además, se realizaron evaluaciones de otros algoritmos de aprendizaje profundo utilizando los mismos conjuntos de imágenes, con el propósito de comparar su rendimiento contra los algoritmos propuestos. Se analizaron tanto los valores de precisión en la clasificación como los tiempos de entrenamiento de los algoritmos.

Como último paso, se desarrollará una interfaz de usuario destinada a médicos, diseñada para ser intuitiva y eficiente. Esta interfaz permitirá a los profesionales médicos llevar a cabo tareas de diagnóstico de manera rápida y efectiva.

1.4.1. Diagrama de bloques del sistema

El sistema de aprendizaje automático está conformado por los siguientes bloques principales:

- Carga de imágenes.
- Entrenamiento del modelo
- Prueba del modelo.
- Clasificación.

La representación gráfica puede verse en la figura 1.1:




Figura 1.1: Diagrama de bloques general del sistema.

Durante la fase de entrenamiento, las radiografías se emplean como entrada del sistema y se someten a un proceso de preprocesamiento destinado a mejorar el contraste y reducir la dimensionalidad, lo que facilita la localización pulmonar. Este subproceso, representado en la figura 1.2, conduce a la obtención de una imagen normalizada, identificada como el número 4 en la figura. Posteriormente, después de la normalización, se ejecuta el proceso de extracción y selección de características para adquirir los datos necesarios que permitirán entrenar el algoritmo clasificador. En este caso, se optó por utilizar los algoritmos K-NN Ponderado y el Perceptrón Multicapa.

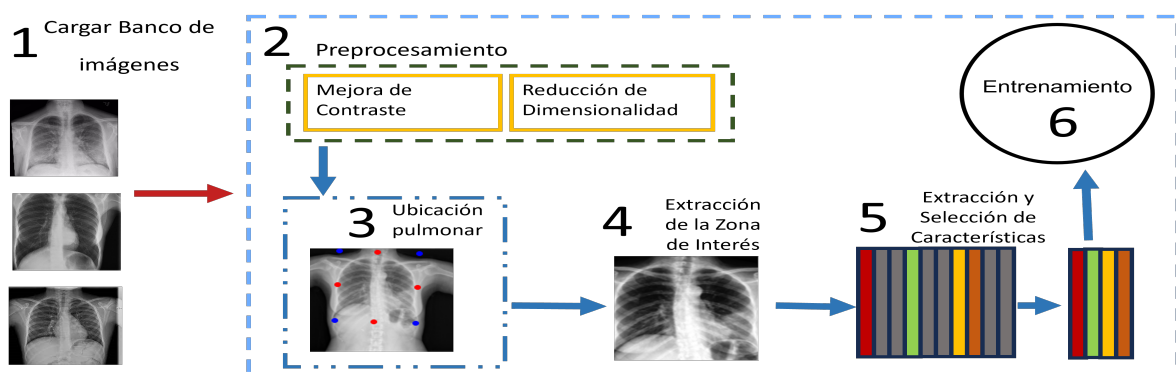


Figura 1.2: Diagrama de bloques de la etapa de entrenamiento.

El subproceso de ubicación pulmonar utiliza un algoritmo automático basado en

regresión K-NN para calcular las coordenadas de la zona de interés. Estas coordenadas se emplean posteriormente en otros procesos, como la normalización de la imagen. Para obtener una descripción detallada del algoritmo localizador de pulmones, se puede consultar la figura 1.3.

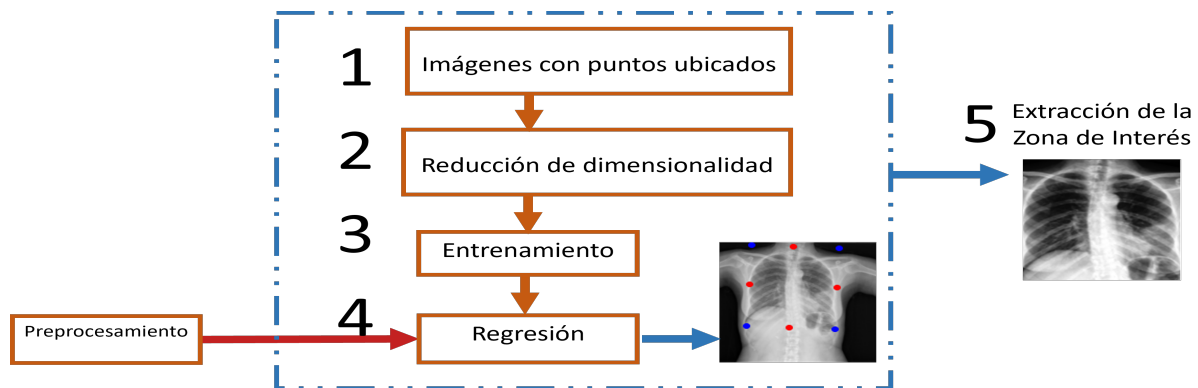


Figura 1.3: Diagrama de bloques de la ubicación pulmonar.

Durante la etapa de prueba, el usuario carga una imagen de prueba que se somete al mismo proceso de preprocesamiento utilizado durante el entrenamiento para igualarla a las imágenes de entrenamiento. A continuación, se aplica el subproceso de ubicación pulmonar para normalizar la zona de interés y, finalmente, se clasifica la imagen. Un esquema de la etapa de prueba se presenta en la figura 1.4. El sistema proporcionará una interfaz de usuario fácil de usar que permitirá cargar la imagen de prueba y mostrará la etiqueta "normal." la probabilidad de que la radiografía presente COVID-19.

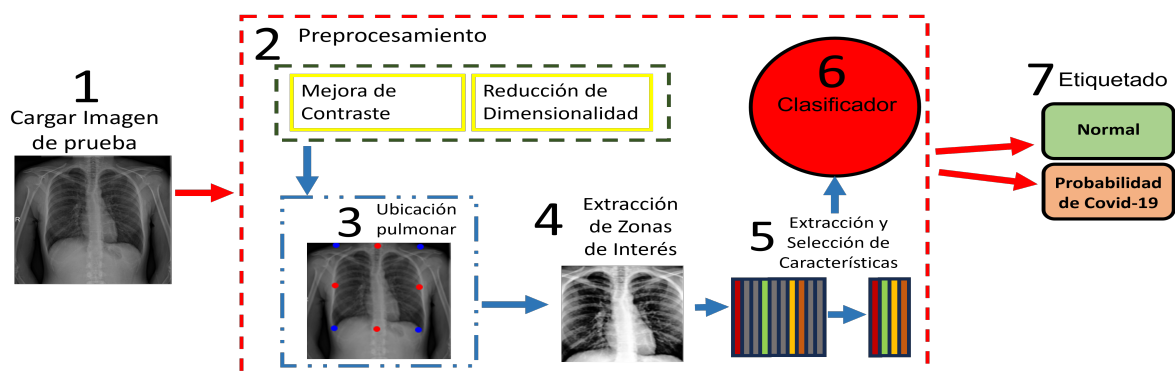


Figura 1.4: Diagrama de bloques de la etapa de prueba.

En resumen, el sistema consta de dos etapas principales: entrenamiento y prueba. Durante la etapa de entrenamiento, se preprocesan las radiografías de entrenamiento, se lleva a cabo la ubicación pulmonar para extraer la zona de interés y se extraen las características relevantes. Por otro lado, en la etapa de prueba, se realiza un proceso similar de preprocesamiento en la imagen de prueba, se lleva a cabo la ubicación pulmonar y se procede a la clasificación de la imagen.

1.5. Organización de la Tesis

Capítulo 1: Introducción: En este capítulo, se proporciona una introducción al tema de investigación, incluyendo una revisión del estado del arte, una exposición de los objetivos y una descripción del diagrama de bloques del sistema general. Esta sección brinda a los lectores una visión completa de los aspectos clave que se abordarán en la tesis.

Capítulo 2: Marco Teórico: Este capítulo aborda el marco teórico de la tesis, que incluye conceptos fundamentales en el aprendizaje automático y el aprendizaje profundo. Además, se describen técnicas de mejora de contraste, el método de reducción dimensional .Ei^{genfacesz} la selección de características basada en el criterio de Fisher.

Capítulo 3: Desarrollo del Sistema: En este capítulo, se detalla el desarrollo del Algoritmo Localizador de Pulmones, comenzando por una explicación de la elección y metodología utilizada en la selección del conjunto de imágenes. Luego, se presentan los pasos y enfoques específicos que se emplearon en la programación de este algoritmo. Además, se examina la aplicación de .Ei^{genfacesz} la selección de características. Finalmente, se introduce la propuesta de utilizar la razón de Fisher como un ponderante para las características.

Capítulo 4: Experimentos y Comparaciones: Este capítulo se centra en los experimentos realizados para evaluar el impacto de los algoritmos propuestos en el sistema. Proporciona una descripción detallada de cómo se llevaron a cabo los experimentos, incluyendo las métricas utilizadas para evaluar el rendimiento. Además, se incluye una comparación con las Redes Neuronales Convolucionales (CNNs), que representan la tendencia actual en el estado del arte.

Capítulo 5: Conclusiones y Trabajo Futuro: Las conclusiones de esta investigación destacan los logros obtenidos, así como las contribuciones al campo del aprendizaje de máquinas y la visión por computadora. Además, se identifican áreas de trabajo futuro, lo que proporciona una visión clara de las posibles direcciones que la investigación podría seguir.

Capítulo 2

Marco Teórico

En este capítulo, se exponen los conceptos fundamentales relacionados con el trabajo realizado, con un enfoque central en la Inteligencia Artificial, el Aprendizaje Automático, así como diversas técnicas de mejora de imágenes, extracción de características y algoritmos que fueron evaluados en esta tesis.

2.1. Inteligencia Artificial

El concepto de inteligencia artificial se introdujo en la década de 1950, pero su potencial se ha desarrollado y utilizado ampliamente en los últimos años. Actualmente, la IA tiene un gran impacto en diversas áreas de la vida cotidiana, desde aplicaciones como *chatbots*, publicidad y contenido en redes sociales, hasta aplicaciones en el campo de la salud, como el diagnóstico asistido por computadora (CAD).

La inteligencia artificial es una disciplina dentro de las ciencias de la computación que utiliza algoritmos con el propósito de crear máquinas capaces de mostrar comportamientos considerados inteligentes en seres humanos. Existen diferentes definiciones que describen el concepto de inteligencia artificial, y estas se pueden clasificar en cuatro enfoques principales: sistemas que piensan como humanos, sistemas que piensan racionalmente, sistemas que actúan como humanos y sistemas que actúan racionalmente.

Los dos primeros enfoques se centran en los procesos mentales y el razonamiento, e incluyen técnicas como redes neuronales y robots. Por otro lado, los dos últimos enfoques se refieren a la conducta, como son los sistemas expertos y los agentes inteligentes, respectivamente.

Un sistema se considera inteligente si es capaz de procesar el lenguaje natural para comunicarse, representar el conocimiento para almacenar lo que sabe o percibe de su entorno, poseer razonamiento automático para responder preguntas y extraer conclusiones basadas en la información almacenada previamente, y ser capaz de aprender de manera

automática para adaptarse a nuevos escenarios y detectar nuevos patrones[39, 40].

A pesar de que estas definiciones pueden generar grandes expectativas y hacer pensar en máquinas capaces de resolver cualquier problema como los humanos, la realidad es que la tecnología actual aún no ha alcanzado ese nivel de inteligencia. Las aplicaciones de la IA tienen como objetivo realizar tareas de manera automática y tomar decisiones en entornos de trabajo específicos y controlados. Actualmente, no existe un sistema con una inteligencia similar a la de los seres humanos. Sin embargo, la IA ha dado lugar a la creación de diversas disciplinas que abarcan campos de desarrollo complejos, entre las que se destacan:

- Visión por computadora
- Reconocimiento de patrones
- Robótica
- Razonamiento automático
- Procesamiento de lenguaje natural
- Aprendizaje automático
- Aprendizaje profundo

La inteligencia artificial es una ciencia interdisciplinaria que se nutre de una amplia gama de campos y áreas del conocimiento, incluyendo matemáticas, lógica, estadística, ingeniería de control, procesamiento de imágenes, lingüística, filosofía, psicología, entre otros [4, 40–42]. En este trabajo de tesis, nos enfocaremos en áreas específicas de la inteligencia artificial, como el aprendizaje automático, el aprendizaje profundo y el procesamiento de imágenes. Estas áreas proporcionarán las bases teóricas y metodológicas necesarias para abordar nuestros objetivos y desarrollar algoritmos y herramientas que mejoren el análisis y la clasificación de las radiografías de tórax en relación con la detección de COVID-19.

2.1.1. Aprendizaje de Máquina

El aprendizaje de Máquina, conocido como *Machine Learning*, se refiere a la capacidad de una máquina o sistema para aprender y mejorar sus predicciones de forma autónoma con el tiempo, sin necesidad de intervención humana. Este proceso busca emular el aprendizaje humano basado en la experiencia, permitiendo a las máquinas identificar y comprender patrones y características complejas en grandes conjuntos de datos. El proceso de aprendizaje se lleva a cabo a través de una fase de entrenamiento del sistema, donde se utilizan ejemplos y patrones de entrada para enseñar a la computadora a reconocer y asociar estos elementos. Una vez completada esta etapa, el sistema puede realizar predicciones precisas sobre nuevos datos que no formaron parte del proceso de entrenamiento. En el entrenamiento de sistemas de aprendizaje automático, se emplean cuatro técnicas principales, las cuales se detallan en la tabla 2.1,

que incluye ejemplos de algoritmos, características y ventajas para cada una de ellas [3, 39, 40, 43].

2.1.2. Algoritmo K-NN (K-Nearest Neighbors)

El algoritmo K-NN (K-Nearest Neighbors) es un método de clasificación muy intuitivo y ampliamente utilizado en aprendizaje automático. Su principio básico es que las muestras pertenecientes a la misma clase tienden a agruparse en el espacio de características.

Funcionamiento General:

En K-NN, cada muestra se representa como un punto en un espacio de características multidimensionales, donde cada dimensión corresponde a una característica del conjunto de datos. Cuando se necesita clasificar una nueva muestra, el algoritmo calcula la distancia entre esa muestra y todas las muestras de entrenamiento en el espacio de características [44].

Distancia:

La distancia más comúnmente utilizada es la distancia euclidiana, su fórmula se encuentra en la ecuación 2.5.

$$d(v, X_j) = \sqrt{\sum_{i=1}^p [v_i - x_{ji}]^2} \quad (2.5)$$

Donde $d(v, X_j)$ es la distancia entre la muestra a clasificar (v) y la muestra de entrenamiento X_j . i representa la i -ésima característica de los vectores a comparar, y p es el número total de características o dimensiones del vector.

Parámetro K:

El parámetro K determina cuántos vecinos más cercanos se considerarán al tomar una decisión de clasificación. Elegir el valor óptimo de K es un aspecto crítico de la configuración de K-NN. Un valor demasiado pequeño puede ser sensible al ruido, mientras que un valor demasiado grande puede suavizar las fronteras de decisión.

Clasificación por Votación:

Una vez calculadas las distancias entre la muestra de prueba y todas las muestras de entrenamiento, K-NN selecciona las K muestras más cercanas (los "vecinos más cercanos"). Luego, realiza una votación en función de las clases de estos vecinos. La clase que obtiene más votos se asigna a la muestra de prueba.

Tabla 2.1: Técnicas de Aprendizaje, Ejemplos de Algoritmos, Características y Ventajas.

Técnica de Aprendizaje	Ejemplos de Algoritmos	Características	Ventajas
Aprendizaje No Supervisado	K-medias, Agrupamiento difuso (Fuzzy C-means), Agrupamiento jerárquico, Modelos de mezcla gaussiana, Modelo oculto de Markov	<ul style="list-style-type: none"> ▪ Sin etiquetas en los datos de entrada. ▪ Agrupa datos similares. 	<ul style="list-style-type: none"> ▪ Útil en análisis exploratorio. ▪ Descubre patrones ocultos.
Aprendizaje Semisupervisado	Algoritmos de propagación de etiquetas, Self-training, Co-Training	<ul style="list-style-type: none"> ▪ Combina datos etiquetados y no etiquetados. ▪ Menos etiquetas necesarias. 	<ul style="list-style-type: none"> ▪ Eficiente con datos escasos. ▪ Aprovecha datos no etiquetados.
Aprendizaje por Refuerzo	Q-learning, Deep Q-Network (DQN), Policy Gradient Methods, Actor-Critic	<ul style="list-style-type: none"> ▪ Aprende a través de recompensas. ▪ Toma decisiones secuenciales. 	<ul style="list-style-type: none"> ▪ Útil en robótica y juegos. ▪ Toma decisiones óptimas.
Aprendizaje Supervisado	Máquinas de Vectores de Soporte, Regresión Lineal, Árboles de Decisión, Redes Neuronales, Naive Bayes, k-Nearest Neighbors	<ul style="list-style-type: none"> ▪ Datos etiquetados en clases. ▪ Predicción de eventos futuros. 	<ul style="list-style-type: none"> ▪ Ampliamente utilizado. ▪ Modelos precisos con suficientes datos etiquetados.

Ponderación de Vecinos:

Se puede aplicar una ponderación a los votos de los vecinos. En lugar de contar todos los votos de manera igual, se pueden asignar pesos diferentes a los vecinos según su distancia a la muestra de prueba. Los vecinos más cercanos pueden tener más influencia en la decisión de clasificación que los vecinos más distantes. La ponderación se realiza mediante una función gaussiana de base radial usando la ecuación 2.6:

$$w_j = e^{-\frac{d_j^2}{\sigma^2}} \quad (2.6)$$

Donde w_j es la ponderación, d_j es la distancia entre la muestra a clasificar y el vecino j , y σ es un parámetro que puede elegirse, como la desviación estándar de las distancias. [3, 39]

Ventajas y Desventajas:

K-NN es un algoritmo simple de entender y de implementar. Es efectivo en conjuntos de datos con estructuras de clase no lineales y funciona bien en problemas de clasificación multiclase. Sin embargo, puede volverse computacionalmente costoso en grandes conjuntos de datos, ya que debe calcular la distancia con todas las muestras de entrenamiento durante la clasificación. Además, la elección del valor de K y la métrica de distancia adecuada son cruciales para su rendimiento. En la figura 2.1 puede verse una representación gráfica de K-NN, en la cual hay círculos de color rojo y azul que representan los datos de entrenamiento de dos clases, el círculo amarillo representa la muestra a clasificar y el radio verde representa los k vecinos [43].




Figura 2.1: Representación gráfica del algoritmo K-NN.

2.1.3. Algoritmo Perceptrón Multicapa (Multilayer Perceptron)

El Multilayer Perceptron (MLP) es una poderosa arquitectura de red neuronal artificial ampliamente utilizada en el campo del aprendizaje automático y el procesamiento de datos. Se caracteriza por su capacidad para modelar relaciones y patrones complejos en los datos, lo que lo convierte en una herramienta valiosa para una variedad de aplicaciones.

Composición de Capas:

El MLP se compone de múltiples capas de unidades de procesamiento, conocidas como neuronas. Cada neurona en una capa está conectada a todas las neuronas de la capa siguiente y de la capa anterior. Estas conexiones están ponderadas por pesos que determinan la fuerza y la dirección de la influencia de cada conexión en el procesamiento de la información. [43]

Funciones de Activación:

En el MLP, cada neurona realiza una operación básica mediante una función de activación. Las funciones de activación más comunes incluyen la función sigmoide y la función ReLU (Rectified Linear Unit). Estas funciones introducen no linealidades en la red, permitiéndole capturar relaciones y patrones no lineales en los datos, lo que es esencial para tareas complejas.

Entrenamiento y Retropropagación del Error:

El proceso de entrenamiento del MLP implica ajustar los pesos de las conexiones para que la red pueda aprender tareas específicas, como clasificación o regresión. Un algoritmo fundamental para este propósito es la retropropagación del error. Este algoritmo calcula el error entre las salidas predichas por la red y las salidas esperadas, y luego propaga este error hacia atrás a través de la red para ajustar los pesos en función de ese error. Una época se define como una pasada completa de todos los ejemplos de entrenamiento a través de la red neuronal.

Topología del MLP:

La arquitectura del MLP consta de tres tipos de capas: la capa de entrada, las capas ocultas y la capa de salida. La capa de entrada recibe los datos y cada neurona representa una característica. Las capas ocultas procesan la información de entrada y son cruciales para aprender representaciones intermedias. La capa de salida produce las predicciones finales. El número de capas ocultas y el número de neuronas en cada capa son decisiones de diseño críticas. En la figura 2.2 puede verse una representación gráfica de una topología básica de un MLP. [3, 39, 43]

Aplicaciones del MLP:

El MLP se ha utilizado con éxito en una amplia gama de aplicaciones de aprendizaje automático, que incluyen reconocimiento de voz, procesamiento de imágenes, análisis de texto, predicción financiera, diagnóstico médico y más. Su capacidad para manejar datos complejos y extraer características relevantes lo hace adecuado para problemas diversos.

Consideraciones y Limitaciones:

A pesar de su eficacia, el MLP no está exento de desafíos. Requiere una cantidad suficiente de datos de entrenamiento y ajuste cuidadoso de parámetros. La elección de la función de activación, el número de capas ocultas y otras configuraciones es crucial y puede requerir experimentación [43].




Figura 2.2: Topología básica de un MLP.

2.1.4. Aprendizaje Profundo

El aprendizaje profundo, también conocido como *deep learning*, es una rama del aprendizaje automático que utiliza redes neuronales artificiales de múltiples capas para modelar y resolver problemas complejos. A diferencia de otros métodos de aprendizaje automático que se basan en la ingeniería de características manuales, el aprendizaje profundo permite que el modelo aprenda automáticamente las representaciones y características relevantes de los datos durante la etapa de entrenamiento.

Estas redes neuronales profundas, también llamadas redes neuronales profundas, pueden capturar y procesar automáticamente patrones y características altamente abstractas y complejas en datos, como imágenes, texto o secuencias temporales. Esto ha llevado a avances significativos en campos como el reconocimiento de imágenes, el procesamiento de lenguaje natural, la visión por computadora, la robótica y muchos otros.

Un ejemplo prominente de aplicación de aprendizaje profundo es en el campo de la visión por computadora, donde las redes neuronales convolucionales (CNNs) han demostrado un rendimiento excepcional en tareas de clasificación y detección de objetos en imágenes. Estas redes son capaces de aprender automáticamente características como bordes, texturas y formas a partir de datos de entrenamiento y utilizar esas representaciones para tomar decisiones precisas.

Sin embargo, es importante destacar que el aprendizaje profundo a menudo requiere grandes conjuntos de datos de entrenamiento y recursos computacionales significativos para entrenar modelos profundamente anidados. Además, la interpretación de los resultados de los modelos de aprendizaje profundo puede ser un desafío debido a su complejidad inherente y falta de transparencia.

A pesar de estos desafíos, el aprendizaje profundo ha revolucionado muchas áreas de la inteligencia artificial y sigue siendo un campo de investigación activo con un gran potencial para futuras aplicaciones. En la tabla 2.2 se muestran los algoritmos más importantes de Deep Learning con sus características y ventajas [38, 45].

Tabla 2.2: Algoritmos Importantes de Deep Learning y Sus Características

Algoritmo	Características	Ventajas
Redes Neuronales Convolucionales (CNNs)	<ul style="list-style-type: none"> ▪ Especialmente efectivas para tareas de visión por computadora. ▪ Utilizan capas convolucionales y de pooling para aprender características. ▪ Ampliamente utilizadas en reconocimiento de imágenes y videos. 	<ul style="list-style-type: none"> ▪ Excelente rendimiento en tareas de clasificación de imágenes. ▪ Capacidad para aprender jerarquías de características. ▪ Reducción de la cantidad de parámetros.
Redes Neuronales Recurrentes (RNNs)	<ul style="list-style-type: none"> ▪ Diseñadas para trabajar con datos secuenciales, como texto y series temporales. ▪ Utilizan conexiones recurrentes para mantener información previa. ▪ Aplicadas en procesamiento de lenguaje natural y predicción de secuencias. 	<ul style="list-style-type: none"> ▪ Manejo eficiente de datos secuenciales. ▪ Modelado de dependencias temporales. ▪ Aplicaciones en traducción automática y generación de texto.
Redes Generativas Adversariales (GANs)	<ul style="list-style-type: none"> ▪ Combinan un generador y un discriminador en una competencia. ▪ Utilizadas para la generación de datos realistas, como imágenes y sonidos. ▪ Ampliamente empleadas en la creación de contenido artificial. 	<ul style="list-style-type: none"> ▪ Capacidad para generar datos de alta calidad. ▪ Aplicaciones en la creación de imágenes y videos sintéticos. ▪ Aprendizaje no supervisado efectivo.

2.2. Normalización de datos

La normalización de datos es un proceso en el que se ajustan los valores de las variables para que sigan una cierta escala o distribución predefinida. El objetivo principal de la normalización es facilitar la comparación y el análisis de las variables al eliminar diferencias en las escalas o unidades de medida. Este proceso es especialmente útil en estadísticas, análisis de datos y aprendizaje automático [3, 41, 43].

Existen varios métodos comunes de normalización de datos, incluyendo:

1. **Estandarización (z-score):** En este método, los valores se transforman para que tengan una media de cero y una desviación estándar de uno. La fórmula general para estandarizar un valor x puede verse en la ecuación 2.1 :

$$x_{\text{estandarizado}} = \frac{x - \text{media}}{\text{desviación estándar}} \quad (2.1)$$

2. **Min-Max Scaling:** En este enfoque, los valores se ajustan para que estén en un rango específico, generalmente entre 0 y 1. La fórmula general para aplicar el escalado Min-Max a un valor x puede verse en la ecuación 2.2:

$$x_{\text{escalado}} = \frac{x - \text{valor mínimo}}{\text{rango (valor máximo - valor mínimo)}} \quad (2.2)$$

3. **Escalado Robusto:** Similar al escalado Min-Max, pero utiliza el rango intercuartil (IQR) en lugar del rango completo para manejar valores atípicos.
4. **Normalización L2:** Utilizado en el aprendizaje automático, normaliza un vector dividiendo cada valor por la norma Euclidiana del vector.
5. **Escalado Logarítmico:** A veces, tomar el logaritmo de los valores puede ayudar a reducir la asimetría en los datos.

La elección del método de normalización depende del tipo de datos, el problema que se está resolviendo y el algoritmo que se va a utilizar. La normalización es especialmente importante en algoritmos que dependen de distancias o magnitudes, como el clustering (agrupamiento) y algunos algoritmos de aprendizaje automático, donde las diferencias en la escala de las variables pueden afectar significativamente los resultados [39, 42, 43].

2.3. Métodos de Reducción de Dimensionalidad

Los algoritmos utilizados en el aprendizaje automático tienen la capacidad de extraer información relevante de bases de datos con múltiples características o dimensiones. Sin embargo, a medida que se agregan más características, el modelo se vuelve más complejo, lo que aumenta el tiempo de ejecución y los recursos computacionales necesarios.

La solución a este problema es la reducción de dimensionalidad, que implica la aplicación de técnicas para eliminar las características innecesarias en el modelo de aprendizaje. Al utilizar estas técnicas, se obtienen varios beneficios, entre los cuales se incluyen [38, 41, 43, 45, 46]:

- **Simplificación del modelo:** La reducción de dimensionalidad permite simplificar el modelo al eliminar características redundantes o irrelevantes. Esto facilita su comprensión y mejora la interpretación de los resultados.
- **Mejora del rendimiento computacional:** Al reducir la dimensionalidad, se disminuye la carga computacional requerida para entrenar y ejecutar el modelo. Esto conlleva a un mayor rendimiento y eficiencia en términos de tiempo de ejecución.
- **Prevención del sobreajuste:** El sobreajuste ocurre cuando el modelo se adapta demasiado a los datos de entrenamiento, perdiendo capacidad de generalización. La reducción de dimensionalidad puede ayudar a evitar el sobreajuste al eliminar características que no contribuyen significativamente a la predicción.
- **Manejo de datos dispersos:** En casos donde los datos presentan alta dimensionalidad y una gran cantidad de características, la reducción de dimensionalidad permite lidiar con problemas de datos dispersos y mejorar la eficacia del modelo.

2.3.1. Análisis de Componentes Principales (PCA)

El Análisis de Componentes Principales (PCA) es un método estadístico que simplifica la complejidad de bases de datos con un gran número de características o dimensiones mientras conserva su información. PCA pertenece a las técnicas de aprendizaje no supervisado.

Para comprender mejor PCA, es útil adoptar un enfoque geométrico. Supongamos un conjunto de observaciones con dos variables (X_1 , X_2). El vector que define la primera componente principal, Z_1 (en rojo), sigue la dirección en la cual las observaciones tienen la mayor variabilidad [47? ?], como se muestra en la Figura 2.3.




Figura 2.3: Primera componente principal del conjunto de datos.

La segunda componente, Z_2 (en verde), sigue la segunda dirección en la que los datos muestran una mayor variabilidad y que no está correlacionada con la primera componente. Cuando dos componentes no están correlacionadas, significa que sus direcciones son perpendiculares, como se ilustra en la Figura 2.4.




Figura 2.4: Primera y segunda componente principal del conjunto de datos.

Las imágenes utilizadas en este trabajo de tesis tienen un gran número de características, por lo que el número de componentes será mayor. Sin embargo, se descartan las componentes con menor varianza, obteniendo un conjunto de componentes principales que describen la variabilidad de la base de datos con la menor información posible.

Cálculo de componentes principales.

Cada componente principal Z_i se obtiene mediante la combinación lineal de las variables originales, como se muestra en la ecuación 2.1. La primera componente principal de un grupo de variables (X_1, X_2, \dots, X_p) es la combinación lineal normalizada de estas variables que tienen una mayor varianza [46]. La ecuación de normalización se presenta en la ecuación 2.2:

$$Z_1 = \phi_{11}X_1 + \phi_{21}X_2 + \dots + \phi_{p1}X_p \quad (2.1)$$

$$\sum_{j=1}^p \phi_{j1}^2 = 1 \quad (2.2)$$

Los términos $\phi_{11}, \phi_{21}, \dots, \phi_{p1}$ se conocen como pesos y representan la importancia de cada variable en cada componente. Una vez calculada la primera componente, se procede a calcular la segunda componente, asegurándose de que la combinación lineal esté no correlacionada con la primera. El orden de importancia de las componentes se determina por la magnitud de los eigenvalores asociados a cada eigenvector.

2.3.2. Eigenfaces

El método de Eigenfaces utiliza el Análisis de Componentes Principales (PCA) para reducir la dimensionalidad de un conjunto de imágenes y representar los datos originales con un número considerablemente menor de componentes o dimensiones. El principal objetivo de este método es encontrar combinaciones lineales de las variables originales que puedan representar la varianza de manera altamente efectiva. Esto significa que con solo unas pocas combinaciones lineales, es posible capturar la mayor parte de la información contenida en el conjunto original de imágenes [48, 49]. Además, las componentes generadas por este método son ortogonales e independientes. Un aspecto destacado del PCA es que no requiere que los ejemplos u observaciones estén etiquetados, lo que lo convierte en un algoritmo de aprendizaje no supervisado [50].

Para llevar a cabo este método de manera efectiva, es necesario contar con un amplio conjunto de imágenes que presenten condiciones similares en términos de posición, contraste, iluminación y tamaño. En algunos casos, puede ser necesario aplicar técnicas de mejora y procesamiento de imágenes para estandarizar las condiciones de entrada.

La relación entre los vectores individuales y todo el conjunto de datos se establece mediante métodos estadísticos, con un enfoque especial en la covarianza, que es particularmente útil en vectores de múltiples dimensiones. Este enfoque busca identificar relaciones entre las características en estas dimensiones. La covarianza se utiliza para medir las relaciones entre dos dimensiones, y si se mide entre la misma dimensión, se obtiene la varianza. La varianza se calcula mediante la ecuación 2.1, mientras que la covarianza se obtiene con la ecuación 2.2. Para cada muestra, se toma la diferencia entre el valor en X y la media de X , y para el valor en Y se hace lo mismo restando la media de Y . Luego, se suman todos estos resultados y se dividen por el número de muestras menos 1 para calcular la covarianza. Es importante mencionar que, por la propiedad conmutativa, $\text{Cov}(X, Y) = \text{Cov}(Y, X)$.

$$\text{Var}(X) = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2 \quad (2.1)$$

$$\text{Cov}(X, Y) = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) \quad (2.2)$$

Si el valor de la covarianza es positivo, esto indica que ambas variables aumentan proporcionalmente; por el contrario, si el valor es negativo, significa que cuando una variable aumenta, la otra disminuye. Cuando el resultado es igual a cero, esto implica que las variables son independientes. A continuación, se presenta un ejemplo de una matriz de covarianza de n dimensiones.

$$C = \begin{bmatrix} \text{Cov}(x_1, x_1) & \text{Cov}(x_1, x_2) & \dots & \text{Cov}(x_1, x_n) \\ \text{Cov}(x_2, x_1) & \text{Cov}(x_2, x_2) & \dots & \text{Cov}(x_2, x_n) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(x_n, x_1) & \text{Cov}(x_n, x_2) & \dots & \text{Cov}(x_n, x_n) \end{bmatrix}$$

Descripción de los pasos para el método de Eigenfaces

En primer lugar, transformamos las i imágenes de $N \times N$ en el conjunto en vectores de tamaño $N^2 \times 1$. Luego, calculamos la cara media del conjunto de imágenes, que representa el promedio de todos los valores de los píxeles de las imágenes en el conjunto. A continuación, calculamos las diferencias entre cada imagen en el conjunto y la cara media, formando así una matriz A de diferencias con dimensiones $N^2 \times i$. La matriz de covarianza se puede calcular de manera eficiente multiplicando AA^T . Sin embargo, es importante destacar que esta matriz de covarianza sería de tamaño $i \times i$, lo que significa que, para un conjunto de 2000 imágenes, tendríamos una matriz de 2000×2000 , que es muy grande y requiere un alto costo computacional para su utilización.

Como opción más sencilla, podemos calcular la matriz de covarianza como $A^T A$, ya que esta matriz tendrá un tamaño máximo de $N^2 \times N^2$ y no dependerá del tamaño del conjunto de imágenes. Esto se debe a que los eigenvectores de las matrices de covarianza AA^T y $A^T A$ están relacionados por $u_i = Av_i$. Con esta comprensión, podemos calcular los i eigenvalores y eigenvectores de la matriz $A^T A$.

Los eigenvalores están vinculados a sus correspondientes eigenvectores y están ordenados de mayor a menor. Para determinar cuántos eigenvectores utilizar para representar el conjunto de imágenes, podemos realizar la suma de todos los eigenvalores y establecer un porcentaje objetivo. Los eigenvalores que no contribuyan a alcanzar este porcentaje se descartan, ya que representan una menor variabilidad en el conjunto de imágenes. Una vez que hemos acumulado suficiente varianza con la suma de eigenvalores, los eigenvectores correspondientes se utilizan como las eigenfaces que representan la mayor variabilidad en el conjunto de imágenes.

Finalmente, se normalizan los vectores que forman a las eigenfaces. De tal modo que $\|u_i\| = 1$. En la tabla 2.3 se muestran los pasos resumidos necesarios para la obtención de la matriz de eigenfaces [48–51].

Con la matriz de eigenfaces construida, procedemos a utilizarla para encontrar la matriz de pesos Ω , que representará los pesos necesarios en vectores columna para la representación de las imágenes de entrenamiento y prueba en un algoritmo clasificador. La imagen de salida se obtiene mediante una combinación lineal de la matriz de eigenfaces Q con la matriz de pesos Ω y se suma la imagen promedio del conjunto de imágenes. Se puede observar una representación gráfica de la ecuación para la proyección en el espacio de las Eigenfaces y la matriz de pesos Ω en la Figura 2.5.

Tabla 2.3: Pasos para la obtención de Eigenfaces

Paso	Descripción y Ecuaciones
Paso 1	Transformar las i imágenes de $M \times N$ a vectores $MN \times 1$
Paso 2	Cálculo de la Mean Face $\text{mean face} = \frac{1}{N} \sum_{i=1}^N \text{imagen}_i$
Paso 3	Cálculo de las Diferencias con la Mean Face $\text{diferencia}_i = \text{imagen}_i - \text{mean face}$
Paso 4	Cálculo de la Matriz de diferencias $A = \text{diferencia}_1 \text{diferencia}_2 \dots \text{diferencia}_i$
Paso 5	Creación de la Matriz de Covarianza $C = \text{diferencia}_i^T \cdot \text{diferencia}_i$
Paso 5	Cálculo de Eigenvectores y Eigenvalores $\mathbf{u}_i = A \cdot \mathbf{v}_i$
Paso 6	Selección de Eigenvalores y Eigenvectores
Paso 7	Normalización de Eigenvectores

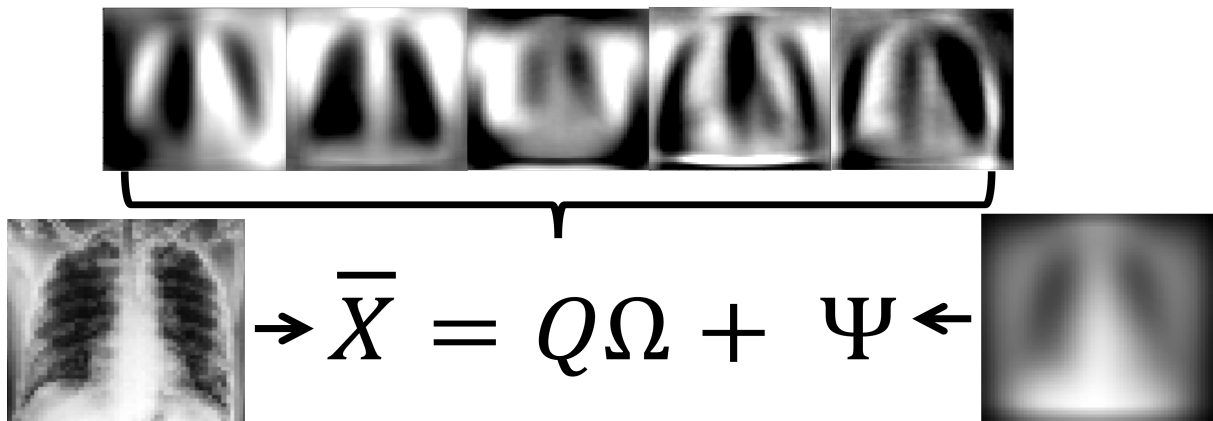


Figura 2.5: La imagen reconstruida X (izquierda) se obtiene utilizando un vector columna de pesos llamado Ω para calcular una combinación lineal de las columnas (eigenfaces expresadas como vectores de columna) de la matriz Q (en el centro), más la imagen promedio (derecha).

2.4. El Criterio de Fisher para la selección de características

Los vectores de características a menudo tienen dimensiones considerables, lo que puede resultar en un aumento en el tiempo de procesamiento de los algoritmos. Además, en numerosos casos, algunas de las características contenidas en estos vectores no son pertinentes para el proceso de clasificación, e incluso pueden tener un efecto negativo al complicar la discriminación entre las clases. La tarea de seleccionar las características apropiadas es altamente compleja, ya que se pueden extraer numerosas características de una imagen, y determinar cuáles son verdaderamente esenciales resulta ser un desafío.

Una forma de evaluar la capacidad discriminativa de las características es observar la distribución de frecuencia de cada clase y establecer un umbral de discriminación. Solo aquellas características que superen este umbral se considerarán relevantes y se utilizarán en el proceso de clasificación.

La Figura 2.6 muestra una representación gráfica del histograma de la distribución de frecuencias de dos clases. Para cada conjunto, es importante analizar tanto la media como la varianza de los datos. En este ejemplo, se puede observar que la característica del lado izquierdo tiene un poder discriminativo menor, ya que la distancia entre las medias de ambas clases es menor en comparación con el lado derecho. Además, en el lado izquierdo, los datos de ambas clases presentan una mayor varianza. Estos indicadores sugieren que la característica representada en el lado izquierdo no posee un buen poder discriminativo [52].




Figura 2.6: Ejemplo de distribuciones de frecuencia para cada clase. La capacidad discriminativa de una característica se puede evaluar visualmente mediante la separación entre los histogramas. El par de histogramas de la derecha muestra una mayor separación, lo que indica una mayor discriminación entre las clases. Por el contrario, el par de histogramas de la izquierda exhibe una menor discriminación.

El criterio discriminante de Fisher, también conocido como la razón discriminante de Fisher o simplemente razón de Fisher (FR) [53], se ha utilizado en el Análisis Discriminante Lineal para encontrar una proyección lineal de características que

maximice la separación entre clases, como se ejemplifica en el reconocimiento facial [?]. Dado que las características del PCA no están completamente correlacionadas y, en cierta medida, son independientes, podemos calcular de manera ingenua la razón de Fisher para cada característica con el fin de medir su capacidad discriminativa y, por ende, estimar su relevancia como característica discriminante.

En el proceso de selección de características, evaluamos el valor de la Razón de Fisher (FR) de forma individual para cada característica de PCA. Utilizamos un enfoque gráfico, como se explica en la Figura 2.6, para calcular las medias y varianzas de las observaciones por separado para las dos clases, denotadas como clase 0 y clase 1. La fórmula para calcular la Razón de Fisher (J) para cada característica se muestra en la ecuación 2.1. En esta ecuación, μ_{ic0} representa la media de la clase 0, μ_{ic1} es la media de la clase 1, σ_{ic0}^2 corresponde a la varianza de la clase 0, y σ_{ic1}^2 es la varianza de la clase 1.

El valor de J es un indicador de la separación entre las clases y la varianza de los datos. Cuanto mayor sea la separación entre clases y menor sea la varianza, mayor será el valor del factor J .

$$J_i = \frac{(\mu_{ic0} - \mu_{ic1})^2}{\sigma_{ic0}^2 + \sigma_{ic1}^2} \quad (2.1)$$

Típicamente, en problemas de dos clases, solo una característica importante sobrevive a este proceso, similar al método de Análisis Discriminante Lineal (LDA) [54, 55], que también utiliza el FR para producir una única característica discriminante en el caso de dos clases. Este enfoque se emplea en Fisherfaces para el reconocimiento de rostros.

En el contexto de la selección de características que se utiliza en esta tesis, se puede proponer un umbral para el valor de J a fin de seleccionar un subconjunto de características p con la mayor capacidad discriminativa de entre el conjunto completo de características m obtenidas a través del PCA (Eigenfaces). Logrando que $p < m$. El FR ha sido utilizado de esta manera en trabajos como [56].

En la Figura 2.7, en el lado izquierdo se muestra el conjunto p de características obtenidas del proceso de Eigenfaces. Para evaluar la capacidad de discriminación de cada característica, se calcula su valor J . Luego, se seleccionan aquellas características que superan un umbral específico para formar un nuevo subconjunto de características m , que puede representar de igual o mejor manera el conjunto de datos original utilizando un número reducido de características.

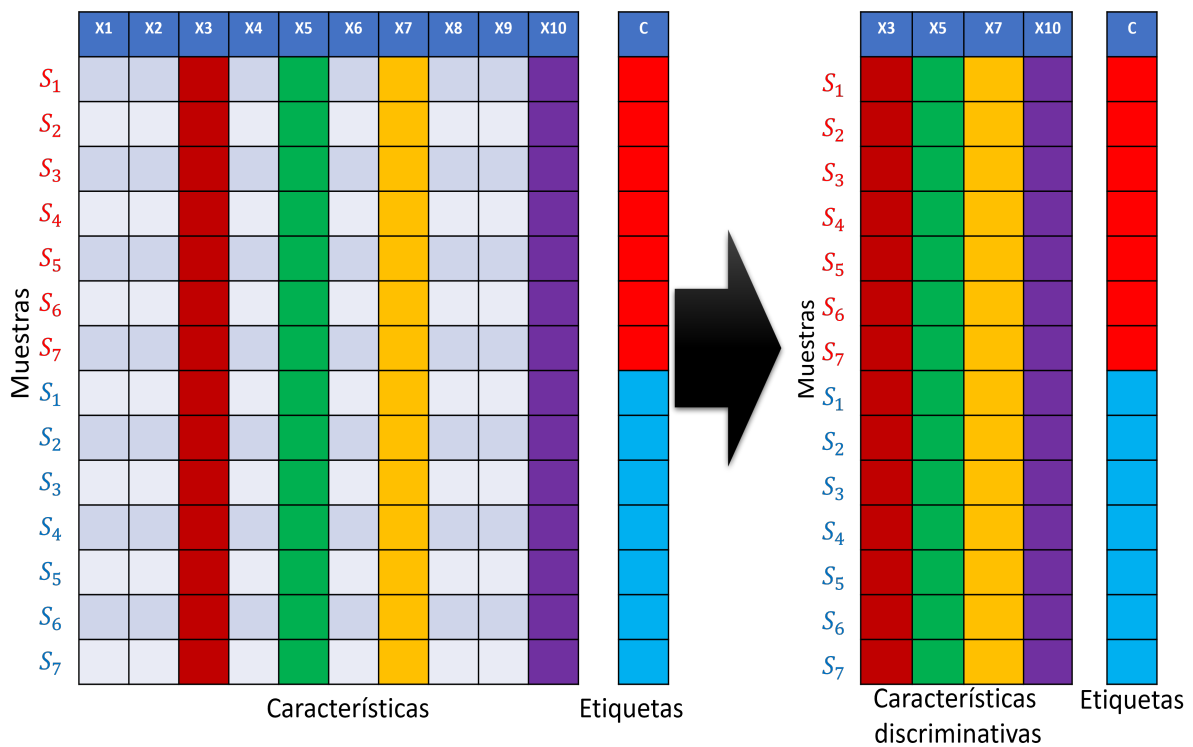


Figura 2.7: Representación gráfica del proceso de selección de características. Al calcular el FR para cada característica, se pueden seleccionar las características que mejor discriminan las clases y formar un subconjunto de características más pequeño y que mejor representan al conjunto de datos original.

2.4.1. La razón de Fisher como ponderante para las características seleccionadas

Se propone utilizar el valor de FR como un ponderante o peso para cada característica ya seleccionada, de modo que aquellas características que posean una mayor capacidad de discriminación tengan un mayor impacto en el proceso de clasificación.

En primer lugar, estandarizamos todas las características seleccionadas para asignarles una relevancia uniforme. Luego, calculamos $\rho_k = \sqrt{J_k}$ para cada característica k . A continuación, normalizamos ρ_k como se muestra en la ecuación 2.1.

$$\varrho_k = \frac{\rho_k}{\sum_{i=1}^k \rho_i} \quad (2.1)$$

Finalmente, cada ϱ_k se utiliza para ponderar todas las observaciones estandarizadas correspondientes a la característica k . En la figura 2.8, se muestra una representación gráfica del proceso de ponderación. Con un conjunto de 4 características, cada vector de características se normaliza y luego se multiplica por su respectivo valor ϱ_k . A través de este proceso, cada característica recibe un peso proporcional a su capacidad para discriminar clases durante la etapa de clasificación mediante algún algoritmo de aprendizaje automático.

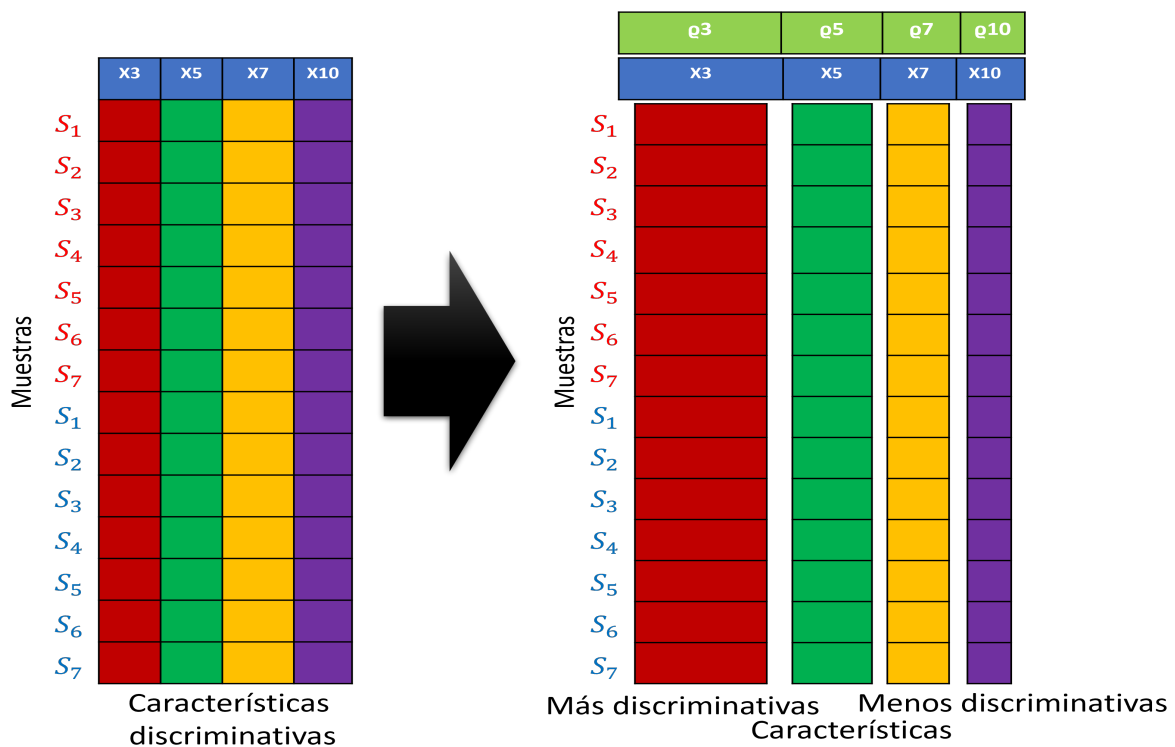


Figura 2.8: Representación gráfica del proceso de ponderación de características. Calculamos el valor ϱ_k para cada característica y luego normalizamos y ponderamos las características por su respectivo ϱ_k . De esta manera, cada característica tiene una importancia en el proceso de clasificación proporcional a su capacidad para discriminar clases.

2.5. Histograma de una imagen en escala de grises

Un histograma de una imagen en escala de grises es una representación gráfica de la distribución de intensidades de píxeles en la imagen. Esta herramienta es fundamental en el procesamiento de imágenes y permite comprender mejor la composición tonal de una imagen en blanco y negro [57, 58].

- **Definición de Intensidad:** En una imagen en escala de grises, cada píxel tiene un valor que representa su intensidad luminosa. Este valor generalmente varía de 0 (negro) a 255 (blanco) en una imagen de 8 bits. Cuanto más alto sea el valor, más claro será el píxel.
- **Construcción del Histograma:** Para crear un histograma, se cuentan la frecuencia de cada valor de intensidad en la imagen. En otras palabras, se cuenta cuántos píxeles tienen una intensidad específica. El eje horizontal del histograma representa los valores de intensidad, y el eje vertical muestra la frecuencia de esos valores.
- **Interpretación del Histograma:** En la interpretación de un histograma de una imagen en escala de grises, varios patrones revelan información sobre la imagen. Por ejemplo, si observamos picos en los valores bajos de intensidad en el histograma, esto sugiere que la imagen es oscura. Por otro lado, si encontramos picos en los valores altos de intensidad, esto indica que la imagen es brillante. Cuando el histograma muestra valores uniformemente distribuidos, refleja una imagen con un equilibrio tonal. Por último, si detectamos picos en valores intermedios, esto puede ser un indicador de que la imagen tiene un alto contraste. Estos patrones en el histograma son clave para comprender las características tonales de una imagen en blanco y negro.
- **Aplicaciones:** Los histogramas de imágenes en escala de grises son esenciales en diversas aplicaciones, como el ajuste de contraste y brillo, la segmentación de imágenes, la eliminación de ruido y la detección de bordes. También se utilizan en el análisis de calidad de imágenes y en la evaluación de la distribución de intensidades en fotografía forense.

En la figura 2.9, se presenta una radiografía de tórax junto con su histograma sin procesar, acompañados por su correspondiente función de distribución acumulada (FDA). La FDA muestra la distribución de los valores de una variable aleatoria a lo largo de su rango completo y cómo se acumulan a medida que aumenta el valor.

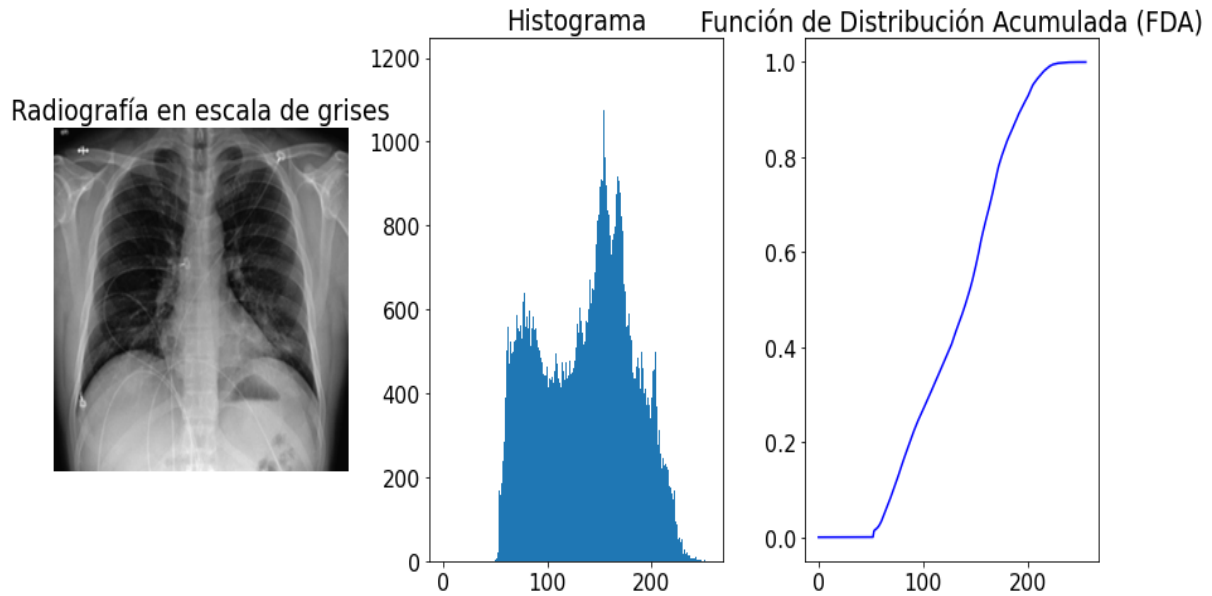


Figura 2.9: Ejemplo de radiografía con su histograma sin procesar. Puede verse que hay valores de gris que no se están utilizando en el histograma. Además puede verse la función de distribución acumulada (FDA).

2.5.1. Ecuación del Histograma

La ecualización del histograma (HE) es un proceso de mejora del contraste en imágenes digitales. Se basa en la redistribución de las intensidades de píxeles en una imagen de manera que se aproveche todo el rango de valores disponibles. Esto resulta en una imagen con un contraste mejorado y detalles más visibles [4, 5, 58].

La ecualización del histograma se puede representar mediante la ecuación:

$$E(i) = \frac{H(i) - H_{\min}}{(M \times N) - H_{\min}} \times (L - 1) \quad (2.1)$$

Donde:

- $E(i)$ es el nuevo valor de intensidad después de la ecualización para el nivel de intensidad i .
- $H(i)$ es el valor acumulado del histograma de la imagen en la intensidad i .
- H_{\min} es el valor mínimo del histograma original (el valor de intensidad más bajo presente en la imagen).
- M es el ancho de la imagen en píxeles.
- N es la altura de la imagen en píxeles.
- L es el número total de niveles de intensidad (generalmente 256 en imágenes en escala de grises).

La ecualización del histograma mejora el contraste de la imagen al estirar los valores de intensidad de manera que cubran todo el rango disponible, lo que resalta los detalles y facilita la detección de características en la imagen.

El resultado de la ecualización del histograma es una imagen en la que los valores de intensidad están mejor distribuidos a lo largo del rango completo, lo que suele resultar en una mejora del contraste y la visibilidad de los detalles. Esta técnica es particularmente efectiva en imágenes en las que la información de interés se encuentra en un rango estrecho de intensidades.

Sin embargo, es importante tener en cuenta que la ecualización del histograma puede aumentar el contraste en toda la imagen, lo que puede no ser deseable en algunas situaciones. Además, no siempre es la mejor opción para todas las imágenes, ya que puede producir efectos no deseados en ciertos casos. En la figura 2.10 puede verse un ejemplo de radiografía con su resultado después de aplicar la ecualización del histograma, además puede verse el cambio en el histograma y la FDA de la imagen.

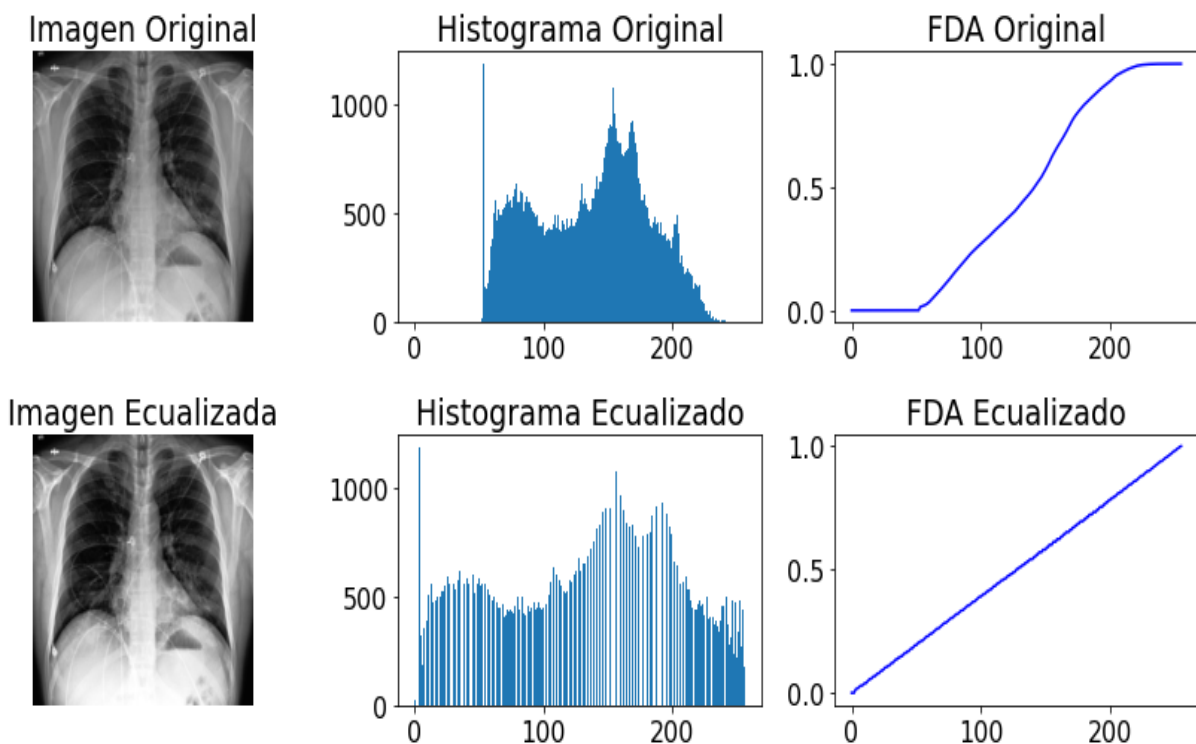


Figura 2.10: Ejemplo de radiografía con su histograma sin procesar y el resultado de la aplicación de la ecualización del histograma. Puede verse que el histograma se extiende en todos los valores de gris. Además puede verse el cambio en la función de distribución acumulada (FDA).

2.5.2. CLAHE (Contrast Limited Adaptive Histogram Equalization)

El CLAHE (Contrast Limited Adaptive Histogram Equalization) es un método de procesamiento de imágenes ampliamente utilizado para mejorar el contraste local en imágenes médicas y de visión por computadora. Es una extensión de la técnica de ecualización del histograma que se utiliza para eliminar problemas como la sobreamplificación de ruido en áreas de bajo contraste [5, 57, 59].

1. **Adaptive Histogram Equalization:** A diferencia de la ecualización de histograma estándar, que aplica la misma transformación de contraste a toda la imagen, el CLAHE divide la imagen en regiones más pequeñas llamadas "parches" y aplica la ecualización de histograma de forma adaptativa a cada parche. Esto permite que el contraste se mejore localmente, lo que es especialmente útil en imágenes donde el contraste varía significativamente en diferentes partes de la imagen.
2. **Limitación del Contraste:** Para evitar que el CLAHE amplifique el ruido en áreas de baja varianza (bajo contraste), se limita el contraste de cada parche individualmente. Esto se hace dividiendo el histograma del parche en intervalos de intensidad y reduciendo los valores de píxeles que exceden un cierto límite de contraste.
3. **Parámetros Configurables:** El CLAHE tiene algunos parámetros configurables, como el tamaño del parche y el límite de contraste. El tamaño del parche controla cuántos píxeles se consideran en cada región local, mientras que el límite de contraste determina cuánto se limita el contraste en cada parche. Ajustar estos parámetros es importante para adaptar el método a diferentes tipos de imágenes y aplicaciones.
4. **Aplicaciones:** El CLAHE se utiliza comúnmente en campos como la radiología médica para mejorar la visualización de detalles en imágenes de rayos X, resonancia magnética y tomografía computarizada. También se utiliza en procesamiento de imágenes de visión por computadora para tareas como reconocimiento de objetos y segmentación de imágenes.
5. **Limitaciones:** Aunque el CLAHE es efectivo para mejorar el contraste local, puede introducir artefactos visuales, especialmente en áreas de transición entre parches. Además, el ajuste de los parámetros puede ser crucial para obtener resultados óptimos.

En la figura 2.11 puede verse un ejemplo de radiografía con su resultado después de aplicar la ecualización del histograma, además puede verse el cambio en el histograma y la FDA de la imagen.

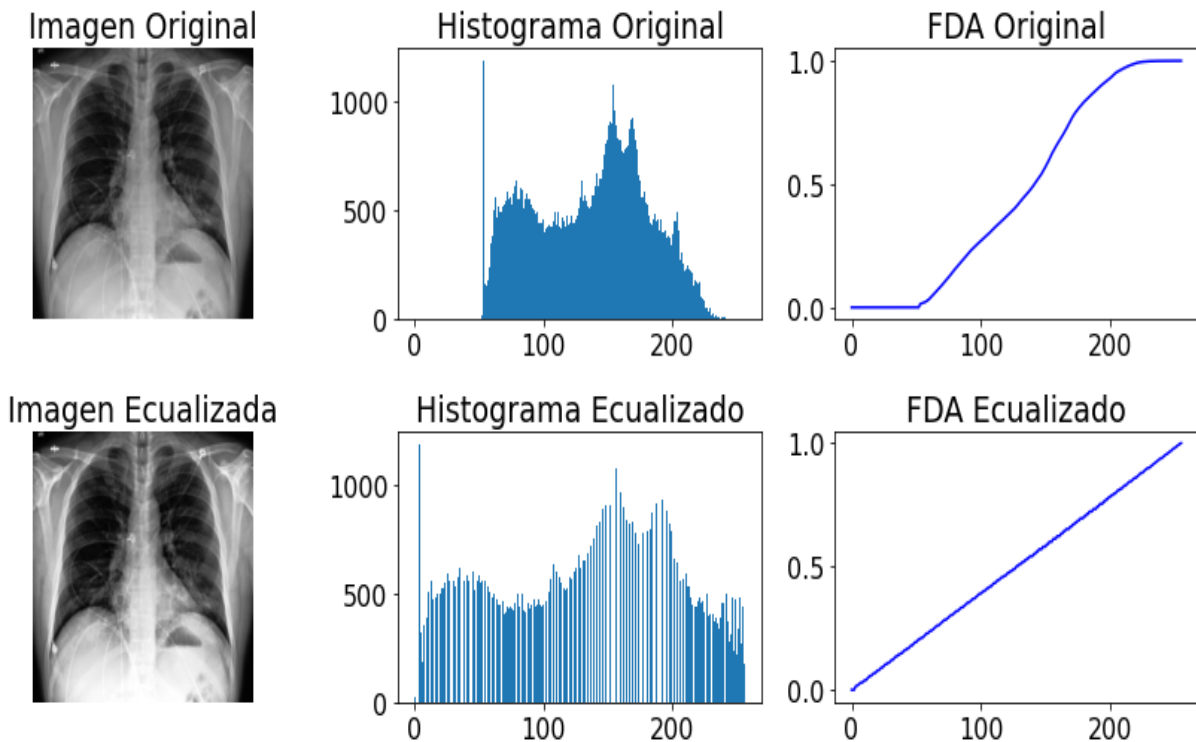


Figura 2.11: Ejemplo de radiografía con su histograma sin procesar y el resultado de la aplicación de CLAHE. Puede verse que en el histograma hay una mejor distribución de valores de gris en los píxel de la imagen. Además puede verse el cambio en la función de distribución acumulada (FDA).

2.6. Image Warping

El *Image Warping* o deformación de imágenes es una técnica en procesamiento de imágenes y visión por computadora que implica la transformación de una imagen para modificar su apariencia o perspectiva. Esta técnica se utiliza en una variedad de aplicaciones, desde la corrección de distorsiones en imágenes hasta la generación de efectos visuales en películas y videojuegos. A continuación se presenta una descripción general de los conceptos clave relacionados con el image warping [5, 57, 60]:

1. **Transformaciones Geométricas:** El image warping implica aplicar transformaciones geométricas a una imagen para deformarla. Estas transformaciones pueden incluir rotaciones, escalas, traslaciones, distorsiones y otros tipos de manipulaciones. Las transformaciones geométricas se aplican a puntos específicos en la imagen y se utilizan para modificar su posición, forma o apariencia.
2. **Aplicaciones Comunes:** El image warping se utiliza en diversas aplicaciones, como corrección de distorsiones de lente en fotografía y vídeo, proyección de imágenes en superficies no planas (como proyectar una imagen en un edificio), corrección de deformaciones en imágenes médicas (por ejemplo, imágenes de

resonancia magnética) y generación de efectos visuales en películas y videojuegos (como distorsionar una imagen para simular un objeto en movimiento).

3. **Mapeo de Puntos:** Para realizar una deformación de imagen, es necesario definir un mapeo de puntos que especifique cómo se transforma cada punto en la imagen original. Esto se hace típicamente mediante una función matemática que asigna coordenadas de entrada a coordenadas de salida. Por ejemplo, en el caso de la corrección de distorsiones de lente, se utiliza un modelo de mapeo para enderezar las líneas curvas en la imagen.
4. **Interpolación:** Cuando se aplica una transformación geométrica, es posible que los puntos de destino no coincidan exactamente con los puntos de origen en la imagen original. La interpolación se utiliza para calcular los valores de píxeles en las ubicaciones intermedias. La interpolación puede ser lineal, bilineal o de orden superior, según la precisión requerida.
5. **Deformación Elástica:** En algunos casos, el image warping implica deformaciones elásticas que permiten cambios locales en la imagen. Esto es útil en aplicaciones como la corrección de deformaciones en imágenes médicas o la animación de personajes en videojuegos.
6. **Herramientas de Software:** Existen numerosas bibliotecas y herramientas de software que facilitan la aplicación de "image warping". Algunos software de edición de imágenes y programas de visión por computadora incluyen herramientas específicas para esta técnica.

En la figura 2.12 puede verse un ejemplo de deformación, en la imagen original puede verse que la figura del *as* se encuentra rotada y trasladada, aplicado la operación *warping*, se puede obtener sólo el *as* en otra perspectiva y tamaño.



Figura 2.12: Ejemplo de aplicación de *warping* a una imagen. Como resultado el *as* obtiene una nueva perspectiva y tamaño.

Capítulo 3

Desarrollo

Este capítulo detalla los procedimientos aplicados para el reconocimiento de COVID-19 en radiografías de tórax. Se inicia con la descripción del conjunto de imágenes empleado. A continuación, se aborda en profundidad el desarrollo del algoritmo Localizador de Pulmones (ALP), desde su fase de entrenamiento hasta su evaluación, destacando su función como subsistema. Una vez normalizadas las imágenes, se implementa el método de reducción de dimensiones mediante las *Eigenfaces*. La selección y ponderación de características se lleva a cabo mediante la aplicación de la Razón de Fisher (FR), identificando así aquellas características con el máximo poder discriminativo entre las clases. Con las características mejoradas, se procede al entrenamiento y prueba utilizando dos algoritmos tradicionales de *Machine Learning*: el K-NN ponderado y el Perceptrón Multicapa (MLP).

3.1. Estructura General

La figura 3.1 presenta un esquema general simplificado de las fases de entrenamiento y prueba del sistema. Dada la variabilidad en la región de interés en las radiografías, se implementa el Algoritmo Localizador de Pulmones (ALP) para la normalización, generando imágenes que contienen exclusivamente la Región de Interés (ROI). La mejora de contraste se realiza mediante CLAHE, con un límite de clip de 1.5 y un tamaño de mosaico de 8 píxeles x 8 píxeles. Esto implica dividir la imagen normalizada en pequeñas regiones de 8 x 8 para mejorar su contraste. Posteriormente, se lleva a cabo la normalización de píxeles para centrar todos los valores en una media de 0 y una desviación estándar de 1.

La aplicación de Eigenfaces resulta en 800 características. La reducción de 65,536 a 800 se realiza para agilizar los tiempos de procesamiento, pero para mejorar la clasificación, se efectúa una selección de características utilizando la Razón de Fisher como criterio para identificar las 600 características con mayor poder discriminativo entre las clases.

Además, se realiza una normalización y ponderación de características, asignando mayor peso a aquellas de mayor importancia durante la clasificación. Finalmente, se emplea un perceptrón multicapa (MLP) como clasificador principal. La red consta de 4 capas ocultas con 120 neuronas y se entrena a lo largo de 100 épocas.

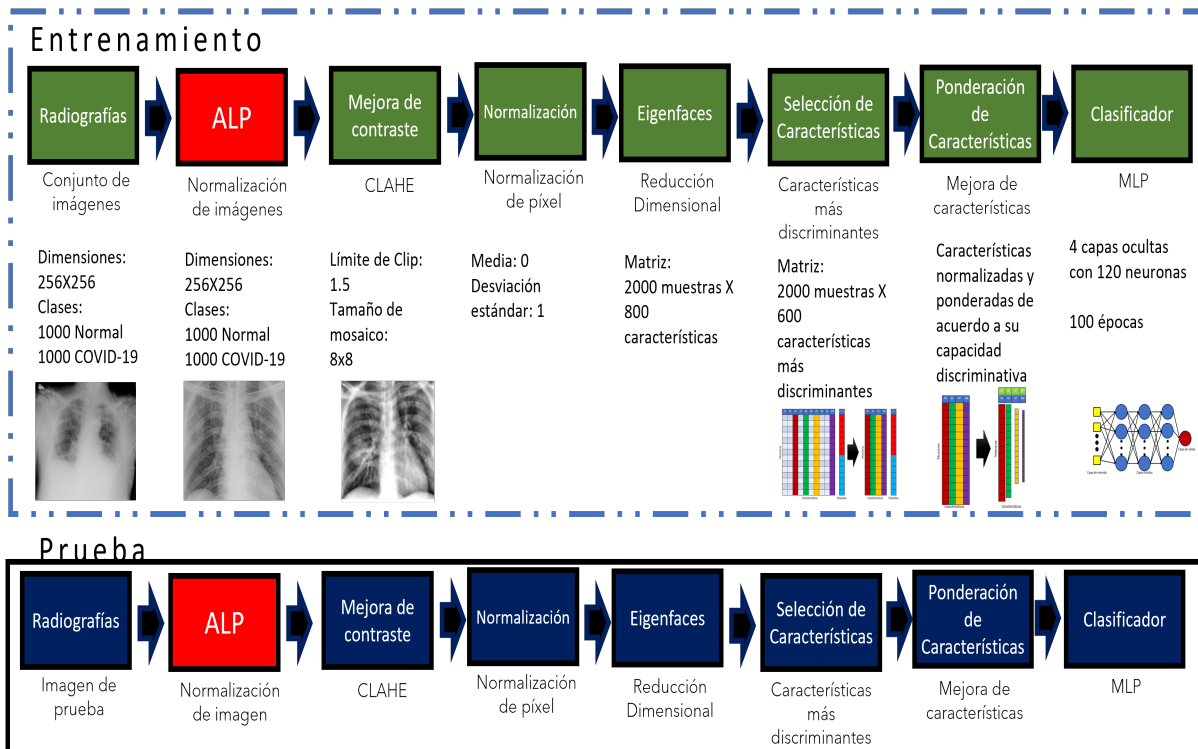


Figura 3.1: Diagrama general del sistema para las etapas de entrenamiento y prueba.

3.2. Conjunto de imágenes radiográficas de tórax

Para el desarrollo de este trabajo de tesis, se ha seleccionado la base de datos "COVID-19 Radiography Database" disponible en kaggle.com [22, 23]. Un grupo de investigadores de la Universidad de Catar en Doha, Catar, y la Universidad de Daca en Bangladés, en colaboración con sus colegas de Pakistán y Malasia, ha establecido una base de datos de imágenes de radiografías de tórax que incluye casos positivos de COVID-19, así como imágenes normales y de neumonía viral. Esta iniciativa se llevó a cabo en estrecha colaboración con profesionales médicos y contiene 33,920 radiografías de tórax ya clasificadas.

En los algoritmos presentados posteriormente, solo se utilizarán las imágenes radiográficas etiquetadas como normales (10,192), COVID-19 (3,616) y neumonía viral (1,345). Es importante destacar que estas radiografías difieren en gran medida en cuanto a posición, rotación, contraste y brillo entre los tres conjuntos, lo que representa un desafío significativo para la correcta ubicación del área de interés (ROI) en los pulmones.

A continuación, se presentan tres ejemplos de la base de datos en la figura 3.2. El primero (izquierda) pertenece a la categoría de "normal", donde el área de interés es más pequeña y el contraste permite distinguir los detalles de los pulmones. El segundo ejemplo (medio) pertenece a la categoría de COVID-19, donde el área de interés está rotada y la imagen presenta una mayor proporción de píxeles en tonalidades blancas, lo que indica un contraste deficiente. La tercera imagen (derecha) pertenece a la categoría de neumonía viral y también presenta un contraste deficiente.




Figura 3.2: Ejemplos de imágenes de la base de datos de Kaggle.

3.3. Mejora del contraste

Se aplicaron técnicas de mejora de contraste, como la ecualización del histograma (HE) y CLAHE, con el objetivo de obtener una visualización mejorada de la información presente en las imágenes. La Figura 3.3 presenta una comparación entre estos métodos. Se destaca que CLAHE ofrece los resultados más notables, ya que la imagen resultante muestra menos áreas oscuras en los pulmones, lo que facilita la apreciación de detalles a simple vista. La presencia de una amplia gama de tonalidades de gris en el área de interés proporciona una mayor cantidad de información, beneficiando a los algoritmos posteriores.



Figura 3.3: Imagen original (derecha), ecualización del histograma(medio), CLAHE (derecha).

3.4. Ubicación de coordenadas

Con el propósito de identificar la región de interés en las imágenes antes de llevar a cabo la normalización de imágenes, se diseñó un programa conocido como "Algoritmo Etiquetador". Este programa posibilita la visualización de la imagen y, de manera interactiva, permite al usuario colocar manualmente las coordenadas de los puntos $Q_i(x_i, y_i)$ en la imagen, guardándolos posteriormente en un archivo independiente. Esto permite al usuario tomar descansos para poder lograr etiquetar toda un conjunto de imágenes. A continuación, se describen los pasos empleados en la implementación en Python, detallados en el Algoritmo 1.

Algoritmo 1: Posición de coordenadas en radiografías

Entrada: Imagen $I(m,n)$.

Salida: Coordenadas $Q_1(x_1,y_1), Q_2(x_2,y_2), Q_3(x_3,y_3), Q_4(x_4,y_4)$

- 1 Inicio;
- 2 Carga de imagen en escala de grises y con dimensiones (64,64). Ecuilizar el histograma de la imagen. ;
- 3 Mostrar imagen en otra ventana.;
- 4 Posicionar P1 y P2 en el área de interés con el mouse.;
- 5 Calcular la recta perpendicular a P1 y P2 que pase por su punto medio.;
- 6 Colocar P3 y P4 en la imagen.;
- 7 Ajustar P3 y P4 en la zona de interés.;
- 8 Guardar P1, P2, P3, P4.;
- 9 Fin;

En la figura 3.4 puede verse el arreglo de puntos $Q_i(x_i, y_i)$, Q1 representa el limite superior de la ROI, Q2 el límite inferior, Q3 el limite izquierdo y Q4 el limite derecho. Este Algoritmo Etiquetador utiliza imágenes en baja resolución para reducir tiempos de procesamiento. Además, utiliza los eventos del *Mouse* para poder colocar los diferentes puntos en la imagen, siendo la siguiente secuencia necesaria para colocar los puntos.

1. Click izquierdo para colocar Q1.
2. Botón central para colocar Q2 y desplegar la recta Q1Q2.
3. Click derecho para desplegar la recta perpendicular a Q1Q2 con los puntos Q3 y Q4 para su ajuste.




Figura 3.4: Arreglo de punto Q.

Cabe destacar que para una mejor visualización de la zona de interés, la imagen desplegada tiene su contraste mejorado mediante la ecualización del histograma. Ya con los puntos colocados el usuario puede mover Q3 y Q4 sobre la recta perpendicular que pasa por el punto medio de Q1 y Q2. Las funciones del Algoritmo Etiquetador se ejecutan al presionar algunas teclas, se presenta la lista completa de funciones, además en la figura 3.5 se presenta la secuencia de funcionamiento:

- Q: Mover punto Q3 a la izquierda.
- W: Mover punto Q3 a la derecha.
- E: Mover punto Q4 a la izquierda.
- R: Mover punto Q4 a la derecha.
- L: Limpiar imagen.
- S: Guardar información.
- X: Cerrar imagen.
- T: Cerrar programa.

Se llevó a cabo el etiquetado manual de 400 imágenes seleccionadas al azar de las clases normal, COVID-19 y Neumonía viral mediante el uso de este algoritmo. Las coordenadas resultantes se utilizaron como nuevas características de las imágenes para su procesamiento posterior.




Figura 3.5: Secuencia de funcionamiento del "Algoritmo Etiquetador".

3.5. Imágenes sintéticas para el aumento de datos

Con el propósito de expandir la base de datos y aumentar la variabilidad de los elementos ya etiquetados, se implementó la técnica de análisis de datos conocida como "data augmentation". Este enfoque se utiliza en diversas tareas de aprendizaje automático, como la clasificación de imágenes, para ampliar conjuntos de datos limitados y prevenir el sobreajuste [38, 43, 45]. Aunque disponíamos de un conjunto considerable de imágenes en la base de datos utilizada [22, 23], se optó por generar radiografías artificiales a partir de las imágenes previamente etiquetadas mediante operaciones aleatorias de traslación y rotación para lograr una distribución normal en los valores de las coordenadas de la región de interés.

En primer lugar, se definió un rango para las operaciones en las imágenes. Para la rotación, se estableció un rango de -10° a 10° (recomendado por [23]), y para la traslación, un rango de -5 a 5 píxeles. Estos valores se determinaron analizando las coordenadas de las 400 imágenes originales del conjunto de imágenes.

A continuación, se generaron 10 imágenes artificiales por cada imagen original, utilizando valores aleatorios dentro del rango establecido. Estas operaciones se aplicaron tanto a la imagen como a las coordenadas de la región de interés. En total, la base de datos del algoritmo ALP consta de 4400 imágenes con una distribución normal en las coordenadas de los puntos. En la Figura 3.6, se muestra un ejemplo de las imágenes artificiales creadas junto con sus respectivas coordenadas de puntos.




Figura 3.6: Elementos sintéticos con sus coordenadas de la ROI generados a partir de una imagen del conjunto de imágenes.

Los pasos para realizar la técnica de *Data Augmentation* para las imágenes pueden verse en el algoritmo 2 a continuación.

Algoritmo 2: Aumento de imágenes

Entrada: Imagen $I(m,n)$, Coordenadas $P1(x1,y1)$,
 $P2(x2,y2), P3(x3,y3), P4(x4,y4)$.

Salida: 10 imágenes sintéticas con sus coordenadas.

```
1 Inicio;
2 Carga de imagen en escala de grises y con dimensiones (64,64).;
3 Carga de coordenadas de la imagen.;
4 Sea  $i = 0$ , el contador de las imágenes creadas.;
5 while  $i$  diferente de 10 do
6     Asignar aleatoriamente un valor de ángulo para la rotación. ;
7     Asignar aleatoriamente valores de coordenadas para la traslación.;
8     Aplicar la rotación a la imagen junto con sus coordenadas.;
9     Aplicar la traslación a la imagen junto con sus coordenadas.;
10    Guardar la imagen junto con sus coordenadas.;
11    Incrementar  $i$ .;
12    Fin;
13 Fin;
```

Se generaron 10 elementos sintéticos para cada imagen del conjunto de imágenes, este número puede ser modificado fácilmente si se requiere. Las coordenadas de la zona de interés de estos elementos se agregan a un archivo general de coordenadas para el ALP.

3.6. Algoritmo Localizador de Pulmones (ALP)

En esta etapa del proyecto de tesis, se requiere desarrollar un algoritmo capaz de ubicar automáticamente los puntos $Q_i (x_i, y_i)$ en las imágenes radiográficas. Para lograrlo, se aplicaron diversas técnicas, como la ecualización del histograma para mejorar el contraste de las imágenes, el uso de Eigenfaces como método de reducción de dimensiones y el algoritmo K-NN en su versión de Regresión para la interpolación de los valores de los puntos $Q_i (x_i, y_i)$. A este programa se le denomina Algoritmo Localizador de Pulmones (ALP). En la figura 3.7 se muestra la secuencia completa de este algoritmo. Es importante destacar que el procesamiento de este algoritmo se hace en imágenes con una resolución de 64x64 y luego se escala a 256X256.

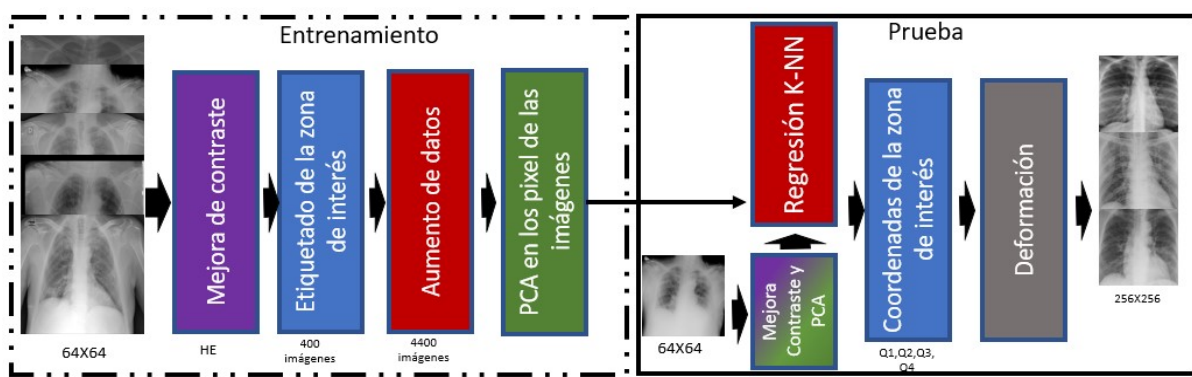


Figura 3.7: Secuencia de los procesos de entrenamiento y prueba del ALP.

Para formar el conjunto de entrenamiento, se seleccionaron aleatoriamente 400 imágenes distintas de los tres conjuntos disponibles (normal, COVID-19, Neumonía viral). Asimismo, se eligieron 100 imágenes de manera similar para constituir el conjunto de prueba. Todas estas imágenes fueron etiquetadas con el *Algoritmo Etiquetador*.

3.6.1. Etapa de entrenamiento del ALP

En la fase de entrenamiento, se utilizaron las 400 imágenes junto con sus coordenadas etiquetadas mediante el *Algoritmo Etiquetador*, y se incluyeron 4000 imágenes generadas mediante *Data Augmentation*, sumando un total de 4400 elementos con una distribución normal. Se aplicó la técnica de ecualización del histograma para mejorar el contraste de todas las imágenes.

Posteriormente, se empleó la técnica de *Eigenfaces*, basada en PCA, para llevar a cabo la reducción de dimensiones en este conjunto de imágenes. Dado que las imágenes tienen una resolución de 64x64, cada píxel se considera una característica, resultando en un total de 4096 características o dimensiones. Mediante el uso de Eigenfaces, se logró reducir estas características a solo 42, las cuales se almacenaron en una matriz de pesos para su posterior utilización en la etapa de prueba. Los pasos para la etapa de

entrenamiento pueden verse detalladamente en el algoritmo 3.

Algoritmo 3: ALP (Entrenamiento)

Entrada: Conjunto de Entrenamiento de 4400 imágenes con sus puntos Q.

Salida: Matriz de pesos y los puntos Q de las imágenes.

- 1 Inicio;
 - 2 Carga de imagen en escala de grises y con dimensiones (64,64).;
 - 3 Ecuilizar el histograma de la imagen. ;
 - 4 Carga de coordenadas de la imagen.;
 - 5 Aplicación de Eigenfaces al conjunto de entrenamiento.;
 - 6 Obtención de la matriz de pesos.;
 - 7 Fin;
-

3.6.2. Etapa de prueba del ALP

El conjunto de prueba está compuesto por 100 imágenes, a las cuales también se les colocaron sus puntos $Q_i (x_i, y_i)$ utilizando el *Algoritmo Etiquetador*. Estas coordenadas se utilizarán para calcular el error que el Algoritmo Localizador de Pulmones (ALP) produce al calcular de manera automática los puntos $Q_i (x_i, y_i)$ en la imagen de prueba. Este error nos permitirá evaluar la efectividad del programa y seleccionar el valor adecuado del parámetro K. A continuación, se presenta el algoritmo 4 utilizado para la prueba del ALP. Después en el algoritmo 5 se muestran los pasos para el calculo del error que existe al interpolar las coordenadas del conjunto de prueba:

Algoritmo 4: ALP (Prueba)

Entrada: Matriz de peso, conjunto de prueba de 100 imágenes con sus puntos Q.

Salida: Puntos Q de las imágenes de prueba.

- 1 Inicio;
 - 2 Carga de la matriz de pesos y coordenadas. ;
 - 3 Carga de los elementos de prueba ;
 - 4 Reducción de dimensionalidad al conjunto de prueba.;
 - 5 KNN()
 - 6 | Calculo de la distancia euclidiana del conjunto de prueba al de entrenamiento.;
 - 7 | Encontrar los k vecinos mas cercanos.;
 - 8 | Asignar un ponderante a los vecinos dependiendo de su distancia al elemento de prueba.;
 - 9 | Calcular las coordenadas mediante la Regresión de los vecinos más cercanos.;
 - 10 Guardar las coordenadas calculadas.;
 - 11 Fin;
-

Algoritmo 5: ALP (Calculo de error)

Entrada: Coordenadas calculadas y reales Q_i de una imagen de prueba.

Salida: Error cuadrático medio de la imagen.

- 1 Inicio;
- 2 Carga de coordenadas calculadas y reales del conjunto de prueba. ;
- 3 Obtener un vector de error para cada punto restándole a la coordenada real la coordenada calculada.;
- 4 Calcular la norma de los vectores de error.;
- 5 Promediar las normas de los vectores.;
- 6 Aplicar raíz cuadrada al promedio.;
- 7 Guardar error cuadrático medio de la imagen.;
- 8 Fin;

El ALP también es capaz de mostrar las imágenes más cercanas a algún elemento de prueba, además de la reconstrucción que puede hacerse de dicha imagen con las Eigenfaces del elemento de prueba. Los vecinos más cercanos son utilizados para el cálculo de las coordenadas de la imagen de prueba mediante regresión, el valor K indica cuantos vecinos más cercanos se utilizan para la regresión. A continuación en las figuras siguientes, se presenta un elemento de prueba 3.8 con sus vecinos más cercanos 3.9 y su reconstrucción 3.10.




Figura 3.8: Elemento de prueba original (derecha), puntos calculadas (medio), puntos reales (izquierda).




Figura 3.9: Vecinos más cercanos a la imagen de prueba.




Figura 3.10: Reconstrucción de la imagen de prueba mediante Eigenfaces.

3.6.3. Error y parámetros del ALP

Los errores cuadráticos medios de las imágenes de prueba se almacenan en un vector para poder observar la influencia del hiperparámetro K en el ALP, se presenta una tabla con los diferentes valores obtenidos para los diferentes valores de K .

Tabla 3.1: Parámetro K para el ALP

	k=3	k=5	k=7	k=9	k=11
Promedio de errores	3.78	3.56	3.54	3.56	3.57
Desviación estándar.	1.76	1.75	1.81	1.86	1.94

Puede verse que el valor de $K = 5$ ofrece mejores resultados para el ALP, debido a que su promedio de errores es el segundo más bajo y tiene la menor desviación estándar. Para futuros usos se mantendrá $K = 5$, es decir las 5 imágenes más parecidas a la imagen de prueba.

3.6.4. Extracción de la región de interés mediante la operación **Warping**

El arreglo de puntos Q_i obtenidos mediante regresión representa los extremos de la zona de interés, sin embargo es necesario realizar una transformación a estos puntos temporales para obtener los puntos definitivos de las esquinas de la ROI para poder utilizar la operación *Image Warping*. A este nuevo arreglo de puntos le llamaremos W_i . Para esta transformación se utiliza la intersección de rectas usando geometría de 2 dimensiones y los pasos se describen en el algoritmo 6. En la figura 3.11 puede verse una comparación del arreglo de puntos Q_i (rojos) y W_i (azul) en la ROI de una radiografía.

Algoritmo 6: Transformación de Coordenadas**Entrada:** Coordenadas calculadas mediante regresión Q_i **Salida:** Coordenadas W_i para la operación Warping

- 1 Inicio;
- 2 Carga de coordenadas Q_i ;
- 3 Calculo de la pendiente m_1 usando los puntos Q_1 y Q_2 ;
- 4 Calculo de la pendiente m_2 usando los puntos Q_3 y Q_4 ;
- 5 Calculo de la recta R_1 usando m_2 y el punto Q_1 ;
- 6 Calculo de la recta R_2 usando m_2 y el punto Q_2 ;
- 7 Calculo de la recta R_3 usando m_1 y el punto Q_3 ;
- 8 Calculo de la recta R_4 usando m_1 y el punto Q_4 ;
- 9 Calculo de W_1 con la intersección de R_1 con R_3 ;
- 10 Calculo de W_1 con la intersección de R_1 con R_4 ;
- 11 Calculo de W_1 con la intersección de R_2 con R_3 ;
- 12 Calculo de W_1 con la intersección de R_2 con R_4 ;
- 13 Entregar arreglo de puntos W_i ;
- 14 Fin;




Figura 3.11: Comparación de los arreglos de puntos Q_i y W_i . El proceso de obtención de los puntos W_i puede verse en el algoritmo 6.

Una vez obtenido el arreglo de puntos W_i , se utiliza la operación de Warping para extraer la región de interés. En la figura 3.12, En la figura 3.12 se presentan ejemplos de las imágenes originales junto con la obtención automática de las coordenadas de la región de interés Q_i (puntos rojos) y las coordenadas utilizadas por la operación de Warping W_i (puntos azules). En el lado derecho de cada radiografía se muestra la imagen normalizada resultante del ALP.




Figura 3.12: Imagen de prueba con su zona de interés extraída.

3.7. Aplicación de Eigenfaces

Luego de normalizar todo el conjunto de imágenes, se realiza una normalización adicional para que los valores de gris tengan una media de 0 y una desviación estándar de 1. A continuación, se implementa el método de "Eigenfaces" para llevar a cabo una reducción dimensional. Este método permite que las imágenes normalizadas se representen como combinaciones lineales en el espacio de las *Eigenfaces*, utilizando los pesos de estas combinaciones como características para el clasificador.

Inicialmente, se cuentan con 65,536 características, lo que podría aumentar significativamente el tiempo de procesamiento de las imágenes. Sin embargo, después de aplicar los pasos del proceso de "Eigenfaces" (ver Tabla 2.3), se logran obtener 800 características que capturan la mayor varianza en el conjunto de imágenes.

3.8. Aplicación de la Selección de Características

Las características derivadas mediante Eigenfaces no siempre poseen una capacidad destacada para discriminar entre diversas clases. Para abordar esta limitación, recurrimos a la Razón de Fisher (FR), que nos ayuda a identificar las características más eficaces para lograr una mejor separación entre las clases. El valor calculado por FR, conocido como J , cuantifica la capacidad discriminativa de una característica.

Durante el proceso de selección, observamos que la primera característica no es necesariamente la más discriminativa, ni la última la menos. Al explorar las 800 características generadas por Eigenfaces, descubrimos que la segunda característica exhibe la mayor capacidad discriminativa, mientras que la característica 57 presenta la menor. Esta clasificación se logra al calcular el valor J para cada característica y ordenarlas de manera descendente.

En las figuras 3.13 y 3.14, se presentan los histogramas correspondientes a la mejor y peor característica, respectivamente. Esta técnica nos permite obtener un conjunto de 600 características que optimizan la discriminación entre las clases.

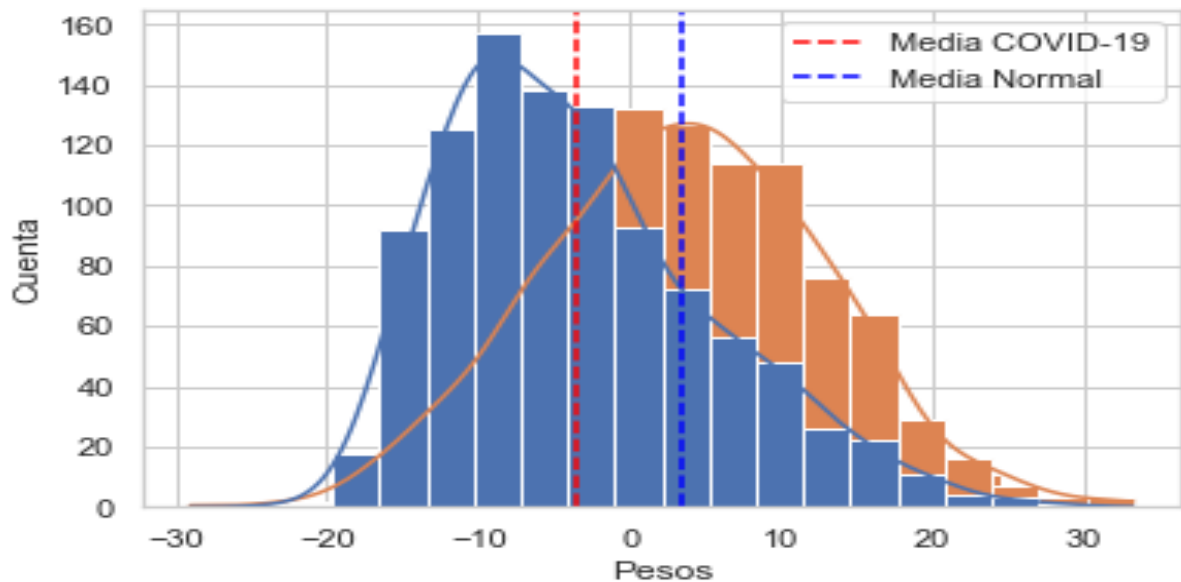


Figura 3.13: Característica con el mayor poder discriminatorio de las clases.




Figura 3.14: Característica con el menor poder discriminatorio de las clases.

3.9. Aplicación de la Ponderación de Características

Los valores J asignados a cada característica también se utilizan como pesos, dando mayor importancia a aquellas con un poder de discriminación superior durante la clasificación. Primero, normalizamos los valores de las características para que oscilen entre 0 y 1. Dado que los valores de J se obtienen elevando al cuadrado las variables, tomamos la raíz cuadrada y luego normalizamos. Dado que la normalización de las 600 características puede ser impráctica de mostrar, presentamos un análisis de un subconjunto de 10 características en la Tabla 3.2. En la Figura 3.15, se representa la proporción de la importancia de cada característica después de esta normalización.

Tabla 3.2: Valores J para el subconjunto de 10 características.

Característica	Valor Original	Valor Normalizado (Decimal)	Valor Normalizado (%)
2	0.2920180	0.2497845	24.98 %
0	0.1294285	0.1662936	16.63 %
8	0.0422516	0.0950129	9.50 %
12	0.0298802	0.0799011	7.99 %
7	0.0290744	0.0788163	7.88 %
5	0.024131	0.0718048	7.18 %
3	0.023088	0.0702350	7.02 %
15	0.0217547	0.0681770	6.82 %
14	0.0179094	0.0618588	6.19 %
29	0.0158075	0.0581155	5.81 %
Suma	0.6253442	1	100 %

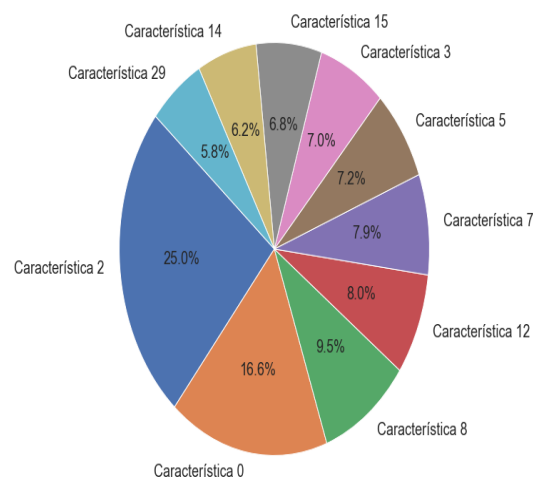


Figura 3.15: Proporción de la importancia de las características basándose en su poder discriminatorio de clases.

Capítulo 4

Resultados

En este capítulo, se exponen los resultados derivados de la aplicación de técnicas de normalización de imágenes, así como la selección y ponderación de características en los algoritmos K-NN ponderado y MLP. También, se lleva a cabo una comparación de los resultados obtenidos cuando estas técnicas no son empleadas en la clasificación de imágenes. Además, se presenta la versión más reciente de la interfaz gráfica utilizada para la clasificación de radiografías. Todas las pruebas descritas en este capítulo fueron realizadas mediante el uso del lenguaje de programación Python y el entorno de desarrollo Spyder.

Con el propósito de realizar una comparación con otros algoritmos utilizados en el estado del arte y para visualizar las contribuciones específicas de este trabajo, se llevó a cabo una comparación con redes neuronales convolucionales. Esto se hizo con el objetivo de destacar las ventajas de las metodologías empleadas en esta tesis.

4.1. Experimentos acerca de la selección y ponderación de características

Se utilizaron 1250 imágenes de COVID-19 y otras 1250 de la categoría normal, ambas con dimensiones de 256x256. A todas estas imágenes se les extrajo la región de interés mediante el uso del ALP. Posteriormente, las imágenes se dividieron en dos conjuntos: uno de entrenamiento, compuesto por 2000 imágenes (1000 de cada clase), y otro de prueba, que consta de 500 imágenes (250 por cada clase).

Se llevaron a cabo varios experimentos con el objetivo de comparar el impacto de cada algoritmo en la precisión de la clasificación. Los algoritmos empleados en las etapas de entrenamiento y prueba fueron los siguientes: ALP para la normalización de imágenes, Eigenfaces para la reducción de dimensionalidad, FR para la selección de las mejores características y W para la ponderación de características según su capacidad de discriminación de clases. Esto da como resultado un total de cinco experimentos para

cada clasificador, los cuales se describen en la figura 4.1. A continuación, se detalla la metodología de los algoritmos para cada experimento.

1. **Experimento Uno:** Las radiografías se utilizan sin aplicar ninguna técnica de mejora de imagen ni de características. Se emplean las 65,536 características al convertir la imagen en un vector.
2. **Experimento Dos:** Las radiografías se someten a una mejora de contraste mediante CLAHE y la Región de Interés (ROI) se extrae mediante el ALP. Se utilizan las 65,536 características al convertir la imagen en un vector.
3. **Experimento Tres:** Las radiografías se someten a una mejora de contraste mediante CLAHE y la ROI se extrae mediante el ALP. Se utilizan 800 características que representan la imagen en el espacio de *Eigenfaces*.
4. **Experimento Cuatro:** Las radiografías se someten a una mejora de contraste mediante CLAHE y la ROI se extrae mediante el ALP. Se utilizan *Eigenfaces* para reducir la dimensionalidad y la razón de Fisher (FR) para seleccionar las 600 características más discriminantes de las clases.
5. **Experimento Cinco:** Las radiografías se someten a una mejora de contraste mediante CLAHE y la ROI se extrae mediante el ALP. Se utilizan *Eigenfaces* para reducir la dimensionalidad, la razón de Fisher (FR) para seleccionar las 600 características más discriminantes de las clases y para ponderar las características en proporción a su capacidad discriminativa.




Figura 4.1: Descripción de los experimentos para las etapas de entrenamiento y prueba de los algoritmos K-NN y MLP.

4.1.1. Resultados y discusiones para el K-NN ponderado

Se probaron diferentes valores para el parámetro K en el K-NN ponderado, y los resultados de los cinco experimentos se encuentran en la Tabla 4.1. Se observó que el valor óptimo de K fue 11. En cuanto a los experimentos, se pueden destacar las siguientes afirmaciones:

1. El experimento uno, donde las imágenes no tienen ningún preprocesamiento, muestra en general los peores resultados.
2. El experimento dos demuestra que la normalización de imágenes mejora los resultados en comparación con el experimento uno.
3. En el experimento tres, donde se proyecta una representación de la imagen en el espacio de las Eigenfaces, no se observa una mejora notable.
4. El experimento cuatro muestra la importancia de la selección de características que mejor separan las clases, lo cual se refleja en una mejora en la precisión.
5. El experimento cinco muestra la eficacia de nuestra secuencia de algoritmos, donde se incluye la normalización de imágenes, la selección de características y el uso del K-NN ponderado.

Estas afirmaciones resaltan la importancia de los diferentes pasos en nuestra metodología y cómo los distintos algoritmos contribuyen a mejorar la precisión en la clasificación. De esta manera, la normalización de imágenes y la selección de características, en conjunto, pueden incrementar la precisión de este clasificador.

Tabla 4.1: Resultado del K-NN ponderado para los experimentos

Parameter K	E1	E2	E3	E4	E5
11	82.4 %	87.8 %	88 %	91.2 %	95.2 %

4.1.2. Resultados y discusiones para el MLP

Para la topología del MLP, se utilizaron 4 capas ocultas, cada una con 120 neuronas, y una única neurona en la capa de salida. El entrenamiento se llevó a cabo durante 100 épocas. A pesar de realizar pruebas con otras topologías y números de épocas, no se encontraron mejoras significativas en la precisión de clasificación.

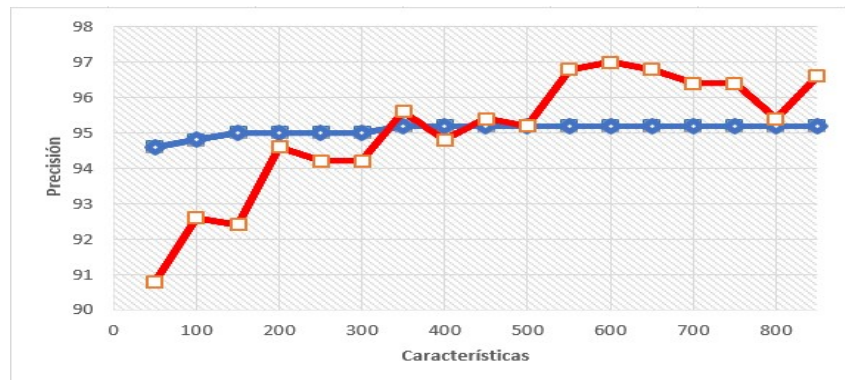
En relación con los experimentos, los resultados son muy similares a los del K-NN en términos de comportamiento, pero ligeramente mejores al lograr un valor de precisión más alto. Esto destaca nuevamente las afirmaciones hechas para el K-NN ponderado. Los resultados para el MLP se presentan en la tabla 4.2 y muestran mejoras leves en comparación con el K-NN ponderado.

Tabla 4.2: Resultados del MLP para los experimentos

E1	E2	E3	E4	E5
85 %	90.6 %	90.8 %	93 %	97 %

4.1.3. Resultados y discusiones adicionales

Se llevaron a cabo pruebas adicionales del experimento 5 variando el número de características para ambos clasificadores. El objetivo era encontrar el número adecuado de características para la clasificación. Las características se ordenaron de manera descendente según su valor J . Los resultados se presentan en la figura 4.2. Se puede observar que el K-NN (en azul) muestra un comportamiento más estable a lo largo de las características, mientras que el MLP tiene un comportamiento más impredecible.

**Figura 4.2:** Variación de características para el K-NN ponderado (azul) y el MLP (rojo).

También al experimento 5 se le aplicó la validación cruzada para poder mostrar la consistencia del conjunto de algoritmos propuestos en esta tesis. En la tabla 4.3 pueden verse los resultados de las 5 pruebas realizadas además del promedio y la desviación estándar para cada clasificador. Después de estas pruebas se tomará sólo el MLP para clasificar las radiografías debido a que muestra mejores resultados de precisión.

Tabla 4.3: Resultados del K-NN ponderado y MLP para la validación cruzada.

Clasificador	Prueba 1	Prueba 2	Prueba 3	Prueba 4	Prueba 5	Promedio	Desviación estándar
K-NN ponderado	95 %	94.8 %	95 %	94.6 %	95.2 %	94.92 %	0.0022
MLP	97 %	96.8 %	96.4 %	97 %	96.8 %	96.8 %	0.0024

4.2. Construcción del MLP

Un MLP tiene varios parámetros que requieren ser optimizados mediante pruebas repetidas, variando ligeramente dichos parámetros para encontrar el valor de precisión más alto. Basándonos en el mejor valor de características obtenido de la gráfica mostrada en la Figura 4.2 y utilizando una topología de cuatro capas ocultas, podemos variar parámetros como el número de neuronas y las épocas de entrenamiento. La Figura 4.3 ilustra cómo la variación en el número de neuronas afecta la precisión del modelo. Tras realizar numerosas pruebas, se determinó que el número óptimo de neuronas es 120.

Asimismo, se llevaron a cabo pruebas con distintos valores de épocas de entrenamiento para evaluar su impacto en la precisión del modelo. Los resultados de estas pruebas se presentan en la Figura 4.4, mostrando que incrementar el número de épocas más allá de 100 no mejora notablemente la precisión del modelo.

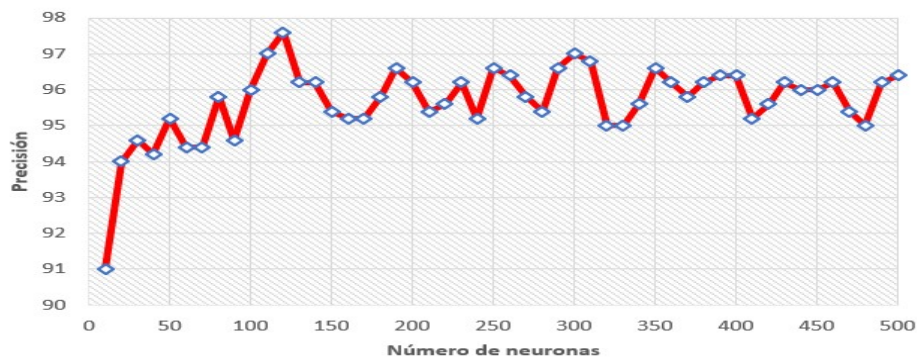


Figura 4.3: Variación del número de neuronas para el MLP.




Figura 4.4: Variación de épocas el MLP.

La topología final del MLP se compone finalmente de una capa de entrada con 600 características, seguida de cuatro capas ocultas, cada una con 120 neuronas. La capa de salida consta de una única neurona. Durante el proceso de entrenamiento, se realizaron 100 épocas para optimizar el modelo.

Pruebas con imágenes etiquetadas con Neumonía

También se llevaron a cabo pruebas al introducir imágenes etiquetadas como Neumonía en la entrada del clasificador propuesto. Esta evaluación implicó probar 300 imágenes y observar la respuesta del sistema. Aunque el clasificador propuesto fue diseñado específicamente para discernir entre COVID-19 y Normal, los resultados de esta prueba revelaron que el 91 % de las imágenes clasificadas como Neumonía fueron identificadas como COVID-19. Este hallazgo sugiere que, a pesar de una tasa de reconocimiento inferior, nuestro clasificador también podría ser útil en el diagnóstico de Neumonía.

4.3. Interfaz de usuario

Ya con el MLP definido, el siguiente paso es desarrollar una interfaz de usuario que permita ejecutar el modelo entrenado para clasificar una radiografía seleccionada por el usuario. Para este propósito, se ha utilizado Python y la biblioteca Tkinter para el desarrollo de la interfaz. En la figura 4.5 se muestra la ventana principal de la interfaz, que representa la última versión de la misma. Esta última versión es capaz de cargar el modelo entrenado y realizar la clasificación de una radiografía, proporcionando tanto la predicción de clasificación como un valor de probabilidad asociado a la presencia de COVID-19 en la radiografía.

El usuario puede interactuar con la interfaz simplemente haciendo clic en el botón *Cargar Radiografía*, lo cual abrirá una ventana de búsqueda que le permitirá seleccionar la radiografía que desea clasificar. Una vez seleccionada la radiografía, al hacer clic en el botón *Procesar*, el clasificador se ejecutará y se mostrará la predicción de clasificación, así como el valor de probabilidad asociado a la presencia de COVID-19 en la radiografía. En la figura 4.6 se muestra un ejemplo con COVID-19 y en la figura 4.7 un ejemplo clasificado como normal.

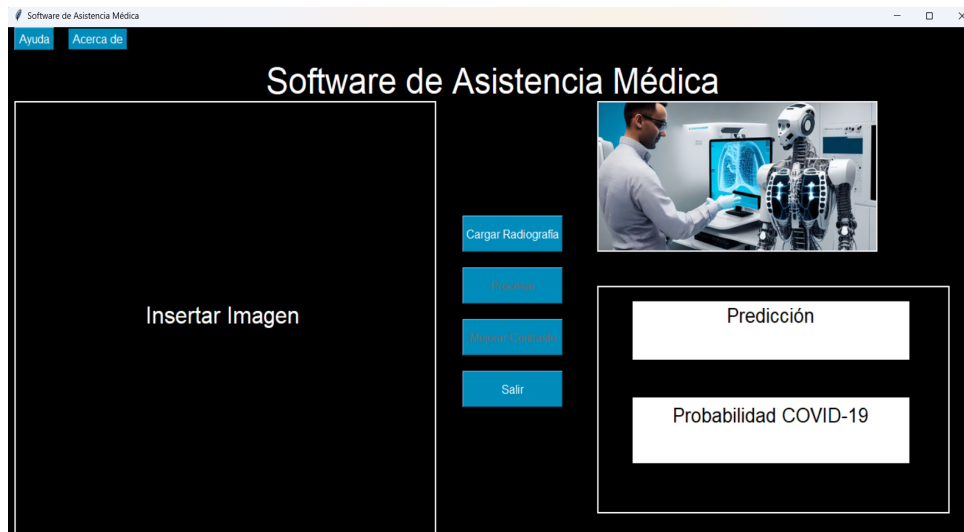


Figura 4.5: Ventana principal de la interfaz de usuario.



Figura 4.6: Imagen clasificada como COVID-19 con probabilidad del 100%.

Los botones *Procesar* y *Mejorar Contraste* se activarán después de que el usuario seleccione una radiografía para su procesamiento. Al utilizar el botón *Mejorar Contraste*, el usuario puede aplicar la técnica de CLAHE. Es importante destacar que esta mejora es exclusivamente para la visualización y no afecta la predicción, como se puede observar en la figura 4.8.

La última versión también incorpora una ventana de ayuda que proporciona instrucciones detalladas para que el usuario pueda utilizar la interfaz de manera efectiva. Además, se ha incluido una ventana *Acerca de*, donde se puede acceder a información detallada sobre la interfaz, que incluye la tasa de reconocimiento, las imágenes admitidas y su resolución, así como información sobre qué sucede al introducir una imagen con neumonía. También se encuentra información sobre los autores del sistema. Estos detalles pueden visualizarse en las figuras 4.9 y 4.10.

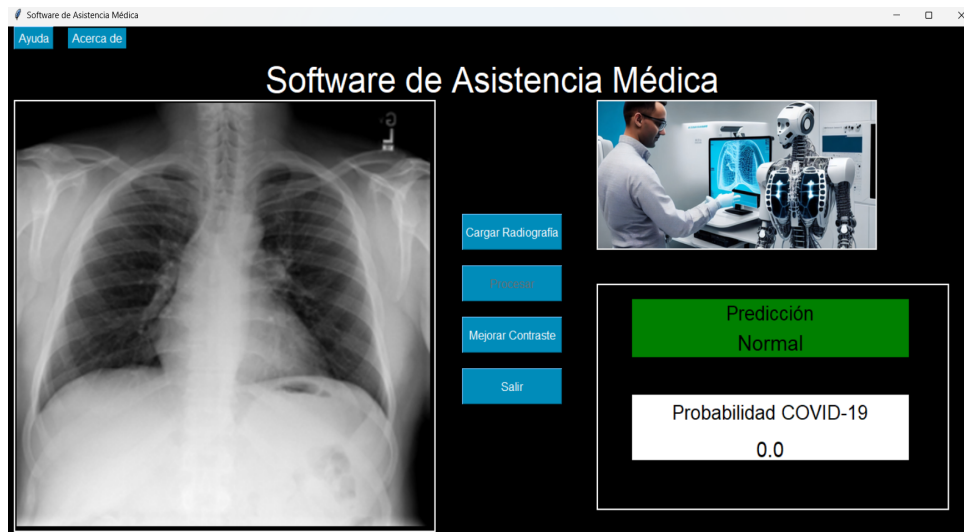


Figura 4.7: Imagen clasificada como Normal con probabilidad del 0%.



Figura 4.8: Imagen después de presionar *Mejorar Contraste*.

4.4. Comparación con redes convolucionales

Las redes neuronales convolucionales, también conocidas como CNN por sus siglas en inglés (Convolutional Neural Networks), son arquitecturas especializadas en el procesamiento de datos estructurados en forma de cuadrícula, como imágenes y señales. Estos algoritmos están en tendencia en el estado del arte. Por esta razón, la comparación con estos algoritmos puede demostrar la eficacia de nuestra propuesta.

Se utilizaron las redes convolucionales MobileNetV2, ResNet-50, ResNet-18, Compact y AlexNet, además de nuestro MLP propuesto, para llevar a cabo la clasificación. Todas las redes convolucionales se implementaron utilizando el software MVTEC Deep Learning Tool 23.04. El proceso de entrenamiento se realizó durante 100 épocas, utilizando un tamaño de lote de 32 y una tasa de aprendizaje de 0.001. En el

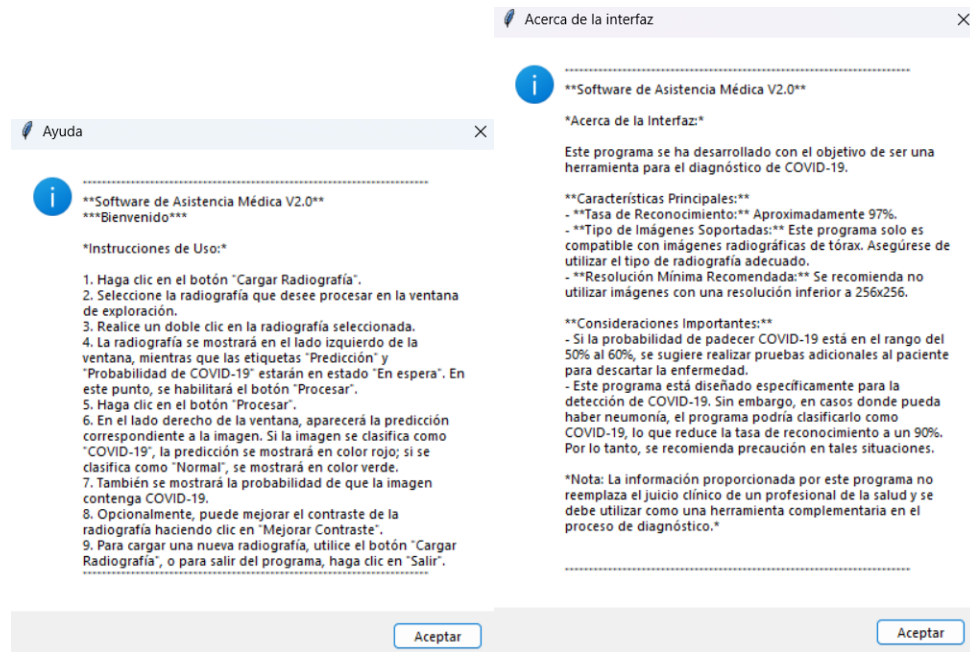


Figura 4.9: Instrucciones en la ventana de ayuda. **Figura 4.10:** Descripción del programa en Acerca de

caso del clasificador propuesto, se emplearon las Eigenfaces para reducir la dimensionalidad de las características y el criterio discriminante de Fisher (FR) para seleccionar y ponderar las características más relevantes en función de su capacidad de discriminación entre clases. Ambos algoritmos se utilizaron en conjunto para mejorar la capacidad de discriminación de las características antes de entrenar el MLP.

La topología del MLP consistió en 600 características para la capa de entrada, seguida de 4 capas ocultas, cada una con 120 neuronas, y una única neurona en la capa de salida. El proceso de entrenamiento se llevó a cabo durante 100 épocas.

Se emplearon 1250 radiografías de COVID-19 y otras 1250 radiografías normales seleccionadas al azar del conjunto de imágenes, todas con una dimensión de 256x256 píxeles. Estas imágenes se dividieron en un conjunto de entrenamiento de 2000 imágenes, con 1000 en cada categoría. Para la fase de prueba, se seleccionaron 500 imágenes, distribuidas equitativamente con 250 por cada clase, asegurando así un conjunto de pruebas balanceado. Utilizando el mismo conjunto de imágenes y el mismo número de épocas de entrenamiento para todos los algoritmos, los valores de precisión obtenidos proporcionan una comparación más precisa del rendimiento de los algoritmos, ya que se están utilizando las mismas condiciones.

La Figura 4.11 muestra la secuencia de los procedimientos realizados en las radiografías para llevar a cabo los experimentos. En el primer experimento, se utilizaron las radiografías sin ningún preprocesamiento. En el segundo experimento, se empleó el Algoritmo Localizador de Pulmones (ALP) de manera automática para realizar la normalización de las radiografías. Ambos experimentos utilizaron las CNNs mencionadas

anteriormente y nuestro clasificador propuesto para el proceso de clasificación de imágenes.




Figura 4.11: . Secuencia de experimentos. En el primero, se lleva a cabo la clasificación sin ningún preprocesamiento para las radiografías. En el segundo, se procede a la normalización de las radiografías mediante el uso del ALP. En ambos experimentos, se realiza la clasificación utilizando CNNs y el clasificador propuesto.

En la tabla 4.4 se muestran los resultados de precisión en la clasificación de todos los algoritmos después de aplicar validación cruzada 5 veces para ambos experimentos.

Clasificador	Radiografías Originales (%)	Normalización con ALP (%)
MobileNetV2	89.0 %	97.6 %
ResNet-50	88.4 %	96.0 %
ResNet-18	88.8 %	96.4 %
Compact	87.0 %	90.8 %
AlexNet	85.2 %	90.0 %
Clasificador Propuesto	88.0 %	97.0 %

Tabla 4.4: Resultados de precisión de las CNNs y el clasificador propuesto para los experimentos.

En primer lugar, se observa que el uso de imágenes originales sin preprocesamiento no es recomendable, ya que se obtienen los peores resultados de clasificación debido a la gran variabilidad en la ROI de las radiografías. En cuanto a la Normalización con ALP, se puede observar que nuestro clasificador propuesto y MobileNetV2 obtuvieron los mejores desempeños. Además, todos los clasificadores experimentaron un incremento en su precisión. Esto se debe a que la variabilidad al usar la Normalización con ALP es menor. En general, se puede afirmar que la normalización de imágenes demuestra ser una representación mejorada para la clasificación de radiografías, independientemente del tipo de clasificador utilizado.

Otra métrica importante a considerar para evaluar estos algoritmos es el tiempo de entrenamiento de cada uno. En la Tabla 4.5, se detallan los tiempos de entrenamiento correspondientes a cada algoritmo. Dado que estos tiempos pueden variar según las características del hardware y el software utilizados durante el entrenamiento, a continuación, se describen las especificaciones del equipo empleado:

■ **Especificaciones del Hardware:**

- Procesador: AMD Ryzen 9 5900HX with Radeon Graphics (16 CPUs), 3.3GHz
- Memoria RAM: 16 GB
- GPU: NVIDIA GeForce RTX 3060 Laptop GPU

■ **Sistema Operativo:**

- Sistema Operativo: Windows 11 Home Single Language 64-bit

■ **Entorno de Desarrollo:**

- Entorno de Desarrollo: SPYDER y MVTEC DEEP LEARNING TOOL

■ **Versión de Software:**

- Versión de Python: 3.11.3
- Versión de OpenCV: 4.7.0
- Versión de NumPy: 1.23.5
- Versión de TensorFlow: 2.12.0
- Versión de MVTEC DEEP LEARNING TOOL: 23.04

Clasificador	Radiografías Originales	Normalización con ALP
MobileNetV2	05:00:18	04:38:41
ResNet-50	08:05:03	07:18:02
ResNet-18	00:22:12	00:20:07
Compact	00:11:12	00:09:13
AlexNet	00:21:18	00:19:43
Clasificador Propuesto	00:07:15	00:06:12

Tabla 4.5: Tiempos de entrenamiento de las CNNs y el clasificador propuesto para los experimentos. (Horas:Min:Seg)

Los extensos tiempos de entrenamiento observados en las redes MobileNetV2 y ResNet-50 podrían atribuirse a su elevado número de parámetros. Dada la arquitectura de las CNNs, los tiempos de entrenamiento tienden a ser significativos según la complejidad interna y la cantidad de parámetros utilizados. Mientras algunos parámetros permanecen constantes en la arquitectura, otros son entrenables, lo que se realiza para mitigar la duración del entrenamiento.

La sencillez de la red AlexNet contribuye a sus breves tiempos de entrenamiento, a pesar de contar con un número considerable de parámetros. Esto se detalla en la Tabla 4.6. Para nuestro clasificador propuesto, todos los parámetros del MLP son entrenables. Resulta notable que, con un tiempo de entrenamiento reducido y un número bajo de parámetros, se logra un rendimiento comparable al de la red MobileNetV2. Estas dos redes, junto con nuestro clasificador, muestran las tasas de precisión más altas en la clasificación de imágenes.

Clasificador	Número Total de Parámetros	Número de Parámetros Entrenables
MobileNetV2	3.5 millones	2.2 millones
ResNet-50	25.6 millones	25.5 millones
ResNet-18	11.2 millones	11.2 millones
Compact	1 millón	1 millón
AlexNet	61 millones	61 millones
Clasificador Propuesto	101,281	101,281

Tabla 4.6: Número total de parámetros y número de parámetros entrenables para cada clasificador.

Capítulo 5

Conclusiones y trabajo futuro

5.1. Conclusiones

En este trabajo de tesis se estableció el problema sobre la falta de alineación en la región de interés (ROI) de las radiografías de tórax. Se propuso una técnica de detección y normalización automática de la ROI en radiografías de tórax, junto con un método enfocado en la selección de características obtenidas mediante PCA basado en el criterio de Fisher (FR) para la detección automática y precisa de COVID-19. Con el método propuesto, se obtiene un número reducido de características altamente discriminativas de las clases. Los resultados evidencian un aumento significativo en la precisión de clasificación de clasificadores tradicionales como el K-NN ponderado y MLP, al aplicar tanto la alineación de ROI como la selección de características, rivalizando con algoritmos del estado del arte como las redes neuronales convolucionales (CNNs).

El Algoritmo Localizador de Pulmones (ALP), propuesto para la alineación de ROI, destaca por su capacidad para buscar y encontrar la ROI en radiografías torácicas, logrando una alineación automática en posición, rotación, escala y contraste. Las imágenes normalizadas generadas por el ALP también demostraron ser capaces de mejorar la precisión de la clasificación de imágenes de algoritmos más complejos que el clasificador propuesto como las CNNs ya que la variabilidad de las imágenes es mucho menor comparada con las radiografías originales. La técnica de reducción dimensional utilizada fue el método de *Eigenfaces*. Además de que el CLAHE fue usado como técnica de mejora de contraste.

El método de selección y ponderación de características toma las características obtenidas del PCA y realiza una evaluación de cada una para poder calcular su capacidad discriminativa de clases mediante el FR. Ya con las características ordenadas conforme a su capacidad de discriminación se utilizó el FR también como un ponderante para que las características con más capacidad discriminativa tengan más influencia en el proceso de clasificación. Con este método se puede generar un conjunto de

características que sean altamente discriminatorias y puedan ser utilizadas en algoritmos tradicionales de *Machine Learning* para mejorar su desempeño.

La confiabilidad de los resultados se respalda con técnicas de validación cruzada. Además, se destaca que la normalización de imágenes y la selección de características, tanto en conjunto como por separado, tienden a mejorar la precisión de la clasificación, un hallazgo consistente durante la ejecución de los diversos experimentos. Durante estos experimentos, también se realizó una comparación con CNNs, y los resultados indican que los algoritmos propuestos en esta tesis pueden competir o superar el porcentaje de precisión en la clasificación, además de lograr un entrenamiento en menor tiempo. Los algoritmos fueron implementados en Python junto con una interfaz de usuario que puede ser utilizada como herramienta para el diagnóstico de COVID-19.

Las principales aportaciones al campo del *Machine Learning* de este trabajo de tesis consisten en el ALP y en un método para la selección y ponderación de características. EL ALP es un algoritmo basado en el K-NN ponderado y tiene como objetivo la búsqueda y alineación de la ROI para formar imágenes normalizadas. La selección de características esta basada en el FR y la ponderación de características es una propuesta que usa el FR para otorgarle mas importancia a las características que mejor discriminen a las clases. Nuestro clasificador propuesto y utilizado en la interfaz gráfica utiliza ambos algoritmos en secuencia para el procesamiento de radiografías.

5.2. Trabajo Futuro

Para futuras investigaciones, se sugiere extender la aplicación del algoritmo propuesto para la normalización de imágenes (ALP), junto con la técnica de selección y ponderación de características del PCA, a conjuntos de imágenes adicionales para la detección de COVID-19 u otras enfermedades pulmonares.

El MLP utilizado fue específicamente diseñado para la detección de COVID-19; sin embargo, en investigaciones posteriores, se podría explorar la posibilidad de utilizar la normalización de imágenes para entrenar y desarrollar un MLP capaz de clasificar diversas enfermedades pulmonares. Además, se considera que la tasa de precisión de reconocimiento podría mejorarse mediante la implementación de una normalización no rígida de la región pulmonar en una nueva versión del ALP.

Finalmente, se sugiere la exploración del análisis de componentes independientes (ICA) en combinación con el método de selección de características basado en FR. Esta combinación podría conducir a la obtención de características aún más discriminatorias para mejorar la capacidad de clasificación del sistema.

Bibliografía

- [1] H. Fujita, “Ai-based computer-aided diagnosis (ai-cad): the latest review to read first,” *Radiological Physics and Technology*, vol. 13, pp. 6–19, 2020.
- [2] C.-M. Chen, Y.-H. Chou, N. Tagawa, and Y. Do, “Computer-aided detection and diagnosis in medical imaging,” *Computational and Mathematical Methods in Medicine*, vol. 2013, 2013.
- [3] R. Duda, P. Hart, P. Hart, and D. Stork, *Pattern Classification*. No. parte 1 in 11/04 16:50:48 GMT, Wiley, 2001.
- [4] R. Gonzalez and R. Woods, *Digital Image Processing, Global Edition*. Pearson Education, 2018.
- [5] R. Szeliski, *Computer Vision: Algorithms and Applications*. Berlin, Heidelberg: Springer-Verlag, 1st ed., 2010.
- [6] T. Cleophas and A. Zwinderman, *Machine Learning in Medicine – A Complete Overview*. 01 2020.
- [7] P. Daszak, G. T. Keusch, A. L. Phelan, C. K. Johnson, and M. T. Osterholm, “Infectious disease threats: A rebound to resilience,” *Health Aff (Millwood)*, vol. 40, pp. 204–211, Feb 2021.
- [8] O. W. in Data, “Covid-19 data explorer.” <https://ourworldindata.org/explorers/coronavirus-data-explorer>, 2022. Accessed: February 2022.
- [9] M. A. Mustafa Ghaderzadeh and F. Asadi, “X-ray equipped with artificial intelligence: Changing the COVID-19 diagnostic paradigm during the pandemic,” *BioMed research international*, vol. 2021, p. 9942873, 2021.
- [10] M. Laino, A. Ammirabile, A. Posa, P. Cancian, S. Shalaby, V. Savevski, and E. Neri, “The applications of artificial intelligence in chest imaging of covid-19 patients: A literature review,” *Diagnostics*, vol. 11, p. 1317, 07 2021.

- [11] E. A. Akl, I. Blažić, S. Yaacoub, G. Frija, R. Chou, J. A. Appiah, M. Fatehi, N. Flor, E. Hitti, H. Jafri, *et al.*, “Use of chest imaging in the diagnosis and management of covid-19: A who rapid advice guide,” *Radiology*, vol. 298, pp. E63–E69, 2021.
- [12] G. D. Rubin, C. J. Ryerson, L. B. Haramati, N. Sverzellati, J. P. Kanne, S. Raoof, N. W. Schluger, A. Volpi, J.-J. Yim, I. B. K. Martin, *et al.*, “The role of chest imaging in patient management during the covid-19 pandemic: A multinational consensus statement from the fleischner society,” *Radiology*, vol. 296, pp. 172–180, 2020.
- [13] N. Sverzellati, G. Milanese, F. Milone, M. Balbi, R. E. Ledda, and M. Silva, “Integrated radiologic algorithm for covid-19 pandemic,” *Journal of Thoracic Imaging*, vol. 35, pp. 228–233, 2020.
- [14] H. Kim, H. Hong, and S. H. Yoon, “Diagnostic performance of ct and reverse transcriptase polymerase chain reaction for coronavirus disease 2019: A meta-analysis,” *Radiology*, vol. 296, pp. E145–E155, 2020.
- [15] Y. Amatya, J. Rupp, F. Russell, J. Saunders, B. Bales, and D. House, “Diagnostic use of lung ultrasound compared to chest radiograph for suspected pneumonia in a resource-limited setting,” *International Journal of Emergency Medicine*, vol. 11, 03 2018.
- [16] M. P. Cheng, J. Papenburg, M. Desjardins, S. Kanjilal, C. Quach, M. Libman, S. Dittrich, and C. P. Yansouni, “Diagnostic testing for severe acute respiratory syndrome-related coronavirus 2,” *Annals of Internal Medicine*, vol. 172, pp. 726–734, 2020.
- [17] J. V. Waller, P. Kaur, A. Tucker, K.-K. Lin, M. J. Diaz, T. S. Henry, and M. Hope, “Diagnostic tools for coronavirus disease (covid-19): Comparing ct and rt-pcr viral nucleic acid testing,” *American Journal of Roentgenology*, vol. 215, pp. 834–838, 2020.
- [18] S. Maheshwari, R. R. Sharma, and M. Kumar, “Lbp-based information assisted intelligent system for covid-19 identification,” *Computers in Biology and Medicine*, vol. 134, p. 104453, 2021.
- [19] C. Qin, D. Yao, Y. Shi, and Z. Song, “Computer-aided detection in chest radiography based on artificial intelligence: a survey,” *BioMedical Engineering OnLine*, vol. 17, no. 1, p. 113, 2018.
- [20] S. Biswas, D. Sen, D. Bhatia, P. Phukan, and M. Mukherjee, “Chest x-ray image and pathological data based artificial intelligence enabled dual diagnostic method for multi-stage classification of covid-19 patients,” *AIMS Biophysics*, vol. 8, no. 4, pp. 346–371, 2021.

- [21] C. Salvatore, M. Interlenghi, C. B. Monti, D. Ippolito, D. Capra, A. Cozzi, S. Schiaffino, A. Polidori, D. Gandola, M. Alì, I. Castiglioni, C. Messa, and F. Sardanelli, “Artificial intelligence applied to chest x-ray for differential diagnosis of covid-19 pneumonia,” *Diagnostics (Basel)*, vol. 11, no. 3, p. 530, 2021.
- [22] M. E. H. Chowdhury, T. Rahman, A. Khandakar, R. Mazhar, M. A. Kadir, Z. B. Mahbub, K. R. Islam, M. S. Khan, A. Iqbal, N. A. Emadi, M. B. I. Reaz, and M. T. Islam, “Can AI help in screening viral and COVID-19 pneumonia?,” *IEEE Access*, vol. 8, pp. 132665–132676, 2020.
- [23] T. Rahman, A. Khandakar, Y. Qiblawey, A. Tahir, S. Kiranyaz, S. B. Abul Kashem, M. T. Islam, S. Al Maadeed, S. M. Zughaier, M. S. Khan, and M. E. Chowdhury, “Exploring the effect of image enhancement techniques on covid-19 detection using chest x-ray images,” *Computers in Biology and Medicine*, vol. 132, p. 104319, 2021.
- [24] A. Clough, A. Sharma, S. Rani, and D. Gupta, “Artificial intelligence-based classification of chest x-ray images into covid-19 and other infectious diseases,” *International Journal of Biomedical Imaging*, vol. 2020, p. 8889023, 2020.
- [25] V. Ravi, H. Narasimhan, C. Chakraborty, and T. D. Pham, “Deep learning-based meta-classifier approach for COVID-19 classification using ct scan and chest x-ray images,” *Multimedia Systems*, vol. 28, no. 4, pp. 1401–1415, 2022.
- [26] K. Rangarajan, S. Muku, S. Banerjee, C. Arora, A. K. Garg, P. Gabra, S. H. Shankar, N. Nischal, K. D. Soni, A. S. Bhalla, A. Mohan, P. Tiwari, S. Bhatnagar, R. Bansal, A. Kumar, S. Gamanagati, R. Aggarwal, U. Baitha, A. Biswas, A. Kumar, P. Jorwal, Shalimar, A. Shariff, N. Wig, R. Subramaniam, A. Trikha, R. Malhotra, R. Guleria, and V. Namboodiri, “Artificial intelligence-assisted chest x-ray assessment scheme for COVID-19,” *European Radiology (Internet)*, vol. 31, no. 8, pp. 6039–6048, 2021.
- [27] N. Tsiknakis, E. Trivizakis, E. E. Vassalou, G. Z. Papadakis, D. A. Spandidos, A. Tsatsakis, J. Sánchez-García, R. López-González, N. Papanikolaou, A. H. Karantanas, and K. Marias, “Interpretable artificial intelligence framework for COVID-19 screening on chest x-rays,” *Experimental and Therapeutic Medicine*, vol. 20, no. 2, pp. 727–735, 2020.
- [28] A. Abbas, M. M. Abdelsamea, and M. M. Gaber, “Classification of COVID-19 in chest x-ray images using DeTraC deep convolutional neural network,” *Applied Intelligence*, vol. 51, no. 2, pp. 854–864, 2021.
- [29] M. Ridzuan, A. A. Bawazir, I. G. Navarette, I. Almakky, and M. Yaqub, “Self-supervision and multi-task learning: Challenges in fine-grained covid-19 multi-class classification from chest x-rays,” 2022.

- [30] V. Changawala, K. Sharma, and M. Paunwala, "Averting from convolutional neural networks for chest x-ray image classification," in *2021 IEEE International Conference on Signal Processing, Information, Communication and Systems (SPICSCON)*, pp. 14–17, 2021.
- [31] B. Mohammed, F. Al-Mukhtar, R. Yousif, and Y. Almashhadani, "Automatic classification of covid-19 chest x-ray images using local binary pattern and binary particle swarm optimization for feature selection," *Cihan University-Erbil Scientific Journal*, vol. 5, pp. 46–51, Nov. 2021.
- [32] S. Samsir, J. Sitorus, Zulkifli, Z. Ritonga, F. Nasution, and R. Watrianthos, "Comparison of machine learning algorithms for chest x-ray image covid-19 classification," *Journal of Physics: Conference Series*, vol. 1933, p. 012040, 06 2021.
- [33] N. Budimirovic, E. Prabhu, M. Antonijevic, M. Zivkovic, N. Bacanin, I. Strumberger, and K. Venkatachalam, "Covid-19 severity prediction using enhanced whale with salp swarm feature classification," *Computers, Materials and Continua*, vol. 72, pp. 1685–1698, 01 2022.
- [34] S. Kadry, V. Rajinikanth, S. Rho, N. Raja, V. Rao, and P. Krishnan, "Development of a machine-learning system to classify lung ct scan images into normal/covid-19 class," 04 2020.
- [35] T. Akram, M. Khan, S. Gul, A. Shahzad, M. Altaf, and Naqvi, "A novel framework for rapid diagnosis of covid-19 on computed tomography scans," *Pattern Analysis and Applications*, vol. 24, 08 2021.
- [36] A. Moberg, U. Taléus, P. Garvin, S.-G. Fransson, and M. Falk, "Community-acquired pneumonia in primary care: Clinical assessment and the usability of chest radiography," *Scandinavian journal of primary health care*, vol. 34, pp. 1–7, 02 2016.
- [37] M. Gómez, "Publicación conmemorativa del 40 aniversario del CMRI." Consejo Mexicano de Radiología e Imagen A. C., CDMX, México, Febrero 2022.
- [38] M. Baig, T. Joseph, and N. Sadvilkar, *The Deep Learning Workshop: Learn the Skills You Need to Develop Your Own Next-Generation Deep Learning Models with TensorFlow and Keras*. Packt Publishing, 2020.
- [39] S. J. Russell, *Inteligencia artificial : un enfoque moderno / Stuart J. Russell y Peter Norvig ; traducción y revisión técnica Juan Manuel Corchado Rodríguez*. Madrid: Prentice Hall, 2^a ed. ed., 2006.

- [40] S. Shalev-Shwartz and S. Ben-David, *Understanding Machine Learning: From Theory to Algorithms*. Understanding Machine Learning: From Theory to Algorithms, Cambridge University Press, 2014.
- [41] W. Ertel and N. Black, *Introduction to Artificial Intelligence*. Undergraduate Topics in Computer Science, Springer International Publishing, 2018.
- [42] D. Mery, *Computer Vision for X-Ray Testing: Imaging, Systems, Image Databases, and Algorithms*. 01 2015.
- [43] H. Saleh, *The The Machine Learning Workshop: Get ready to develop your own high-performance machine learning algorithms with scikit-learn, 2nd Edition*. Packt Publishing, 2020.
- [44] T. Cover and P. Hart, “Nearest neighbor pattern classification,” *IEEE Transactions on Information Theory*, vol. 13, no. 1, pp. 21–27, 1967.
- [45] H. Saleh, *The The Deep Learning with PyTorch Workshop: Build deep neural networks and artificial intelligence applications with PyTorch*. Packt Publishing, 2020.
- [46] I. Jolliffe, *Principal Component Analysis*. Springer Series in Statistics, Springer, 2002.
- [47] F. Márquez, *Advances in Principal Component Analysis*. IntechOpen, 2022.
- [48] M. Turk and A. Pentland, “Eigenfaces for Recognition,” *Journal of Cognitive Neuroscience*, vol. 3, pp. 71–86, 01 1991.
- [49] M. Turk and A. Pentland, “Face recognition using eigenfaces,” in *Proceedings. 1991 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 586–591, 1991.
- [50] M. Kirby and L. Sirovich, “Application of the karhunen-loeve procedure for the characterization of human faces,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 12, no. 1, pp. 103–108, 1990.
- [51] O. Gervasi, V. Kumar, C. Tan, D. Taniar, A. Laganà, Y. Mun, and H. Choo, *Computational Science and Its Applications - ICCSA 2006: International Conference, Glasgow, UK, May 8-11, 2006, Proceedings, Part II*. Lecture Notes in Computer Science, Springer Berlin Heidelberg, 2006.
- [52] S. Shinmura, *New Theory of Discriminant Analysis After R. Fisher: Advanced Research by the Feature Selection Method for Microarray Data*. Springer Nature Singapore, 2016.

-
- [53] S. Theodoridis and K. Koutroumbas, *Pattern Recognition, Fourth Edition*. Academic Press, 2009.
- [54] T. Cacoullos, *Discriminant Analysis and Applications*. Elsevier Science, 2014.
- [55] T. S. Silva, “An illustrative introduction to fisher’s linear discriminant,” <https://sthalles.github.io>, 2019.
- [56] E. Ibis, “Sistema de aprendizaje automático para la detección de neumonía,” master’s thesis, Benemérita Universidad Autónoma de Puebla, Puebla, México, 2022.
- [57] T. B. Moeslund, *Introduction to Video and Image Processing: Building Real Systems and Applications*. Undergraduate Topics in Computer Science, Springer London, 2012.
- [58] Q. Carroll, *Digital Radiography in Practice (2nd Edition)*. Charles C Thomas, Publisher, Limited, 2023.
- [59] F. Joseph, V. Balas, S. Rajest, and R. Regin, *Computational Intelligence for Clinical Diagnosis*. EAI/Springer Innovations in Communication and Computing, Springer International Publishing, 2023.
- [60] G. Wolberg, *Digital Image Warping*. Systems, Wiley, 1990.

Normalización de radiografías de tórax para la detección de neumonía mediante algoritmos tradicionales de aprendizaje de máquina

Salvador Ayala Raggi, Angel Ernesto Picazo Castillo,
Aldrin Barreto Flores, José Francisco Portillo Robledo

Benemérita Universidad Autónoma de Puebla,
México

{saraggi,a.picazo.2505}@gmail.com

Resumen. En este trabajo se presenta una propuesta para la normalización automática de la región de interés (pulmones) en las radiografías de tórax utilizando algoritmos tradicionales de aprendizaje de máquina, esto consiste en lograr que las imágenes sean semejantes en rotación, escala y contraste. Posteriormente se utiliza el PCA como método de reducción de características para las imágenes normalizadas. De estas características obtenidas de PCA se seleccionan las que tienen la mejor capacidad de discriminación de clase usando el criterio de Fisher. La normalización en conjunto con la selección de características demuestran formar un método capaz de lograr que clasificadores como el K-NN ponderado y el MLP puedan obtener precisiones de 89.79 % y 91.24 % respectivamente para la clasificación de imágenes de neumonía. El método propuesto no busca sustituir a los métodos de aprendizaje profundo pero demuestran ser opciones aceptables para la clasificación.

Palabras clave: K-vecinos más cercanos, clasificación de imágenes, determinante lineal de Fisher, neumonía viral.

Chest X-Ray Normalization for Pneumonia Detection Using Traditional Machine Learning Algorithms

Abstract. This work presents a proposal for the automatic normalization of the region of interest (lungs) in chest radiographs using traditional machine learning algorithms. This involves making the images similar in rotation, scale, and contrast. Subsequently, PCA is used as a method for feature reduction for the normalized images. From these PCA features, the ones with the best class discrimination capability are selected using Fisher's criterion. Normalization, together with feature selection, demonstrates a method capable of achieving precision of 89.79% and 91.24% for pneumonia image classification using weighted K-NN and MLP classifiers, respectively. The proposed method does not seek to replace deep learning methods but demonstrates acceptable options for classification.

Keywords: K-nearest neighbors, image classification, Fisher linear determinant, viral pneumonia.

1. Introducción

La Neumonía es una enfermedad pulmonar causada por bacterias y virus, una persona puede ser contagiada por medio del aire, saliva o moco. Además, los niños y las personas mayores tienen un mayor riesgo de ser contagiados, de acuerdo con [1]. En la actualidad, ya existen diversos métodos para la detección de esta enfermedad como las tomografías, radiografías de pecho y ultrasonidos.

Sin embargo, las tomografías son más caras que una radiografía y el ultrasonido no siempre está disponible o asequible, por esto, las radiografías resultan ser un método de detección más común [2, 3, 4, 5, 6]. En la actualidad, existen bancos de información que contienen radiografías ya etiquetadas y pueden ser utilizadas para el entrenamiento de diferentes algoritmos de aprendizaje de máquina [10]. La construcción de estos bancos ha sido un esfuerzo conjunto de instituciones y médicos expertos [7, 8, 9].

El problema con estas imágenes radica en la falta de uniformidad en la región de interés (pulmones), ya que hay algunas que contienen información no deseada o irrelevante para una clasificación, como otras partes del cuerpo u objetos que cubren el pecho; esto puede causar que los algoritmos de clasificación reduzcan sus métricas de precisión [11]. En este trabajo, se proponen dos procedimientos seriados para el tratamiento de las radiografías de tórax.

El primero consiste en la “normalización” de las imágenes, es decir que el banco de información contenga imágenes con su región de interés con la misma alineación, ubicación y escala tanto como sea posible, además de una mejora de contraste. Para el segundo procedimiento, después de obtener dicho banco se procederá a realizar un análisis de las características que las imágenes posean.

Todo esto con el objetivo de encontrar las características que mejor discriminen las clases para que el algoritmo de clasificación incremente su métrica de precisión. Este trabajo comienza con la mención del banco de datos utilizado, continuando en la parte 2 con la descripción, teoría y resultados de nuestro “Algoritmo Localizador de Pulmones” (ALP), todo esto para el procedimiento de normalización.

Después en la parte 3, se menciona la teoría de “Eigenfaces” y del discriminante lineal de Fisher que se utilizaron en nuestro análisis para las características de las imágenes del nuevo banco de datos. Finalmente, se hará la comparación de las métricas de precisión al usar o no usar nuestro procedimiento propuesto utilizando los algoritmos “K -vecinos más cercanos ponderado” (Weighted K-NN) y el “Perceptrón multicapa” (MLP) como clasificadores [12].

1.1. Trabajo relacionado

En la actualidad ya existen diferentes metodologías para la clasificación de radiografías de tórax, como en [24, 25, 7, 16, 17, 18]. Utilizando algoritmos de aprendizaje profundo o clasificadores tradicionales de aprendizaje de máquina [19, 20], reportando precisiones de clasificación superiores al 96 %. Sin embargo, las arquitecturas utilizadas en los algoritmos aún son insuficientes para la clasificación precisa de neumonía causada por COVID-19 [21].



Fig. 1. Ejemplos de la base de datos [24, 25]. Neumonía viral (Derecha), COVID-19 (medio) y Normal (Izquierda).

Esto abre la posibilidad a que se puedan hacer otras propuestas para la clasificación de radiografías y que no estén basadas en redes neuronales convolucionales (CNNs) como en [13] que utiliza un MLP y una arquitectura basada en involución de imágenes reportando una precisión de la clasificación máxima de 94.49 %. La selección de características ha sido capaz de incrementar la precisión de clasificación en otros trabajos.

Como en [14] para su máquina de vectores de soporte o en [15] para su algoritmo K-NN. Los resultados de nuestro trabajo no pretenden sustituir las CNNs para la clasificación de imágenes, sino proponer otra opción, como en [13], y demostrar que nuestro trabajo tiene resultados comparables con algoritmos de aprendizaje profundo.

1.2. Base de datos de imágenes radiográficas

La base de datos utilizada para este trabajo fue "COVID-19 Radiography Database"[24, 25] de Kaggle. Esta base de datos fue seleccionada, ya que ha sido utilizada en otros trabajos similares[26, 27]. El contenido de esta base es 3616 imágenes ya etiquetadas como opacidad pulmonar (otras enfermedades pulmonares), 1345 como Neumonía (algunas causada por COVID-19) y 10,192 como normal (saludable). Como puede verse en la figura 1, la región de interés de las imágenes (Pulmones) presentan diferencias notorias en cuanto a escala, traslación, rotación y contraste.

2. Algoritmo localizador de pulmones (ALP)

Este algoritmo tiene como objetivo localizar los pulmones en las radiografías, también cuenta con su etapa de entrenamiento y prueba como puede verse en 2. Para la primera parte, se seleccionaron 400 imágenes aleatoriamente de las clases Neumonía, COVID-19 y Normal de la base de datos. A todas las imágenes se les aplicó la ecualización del histograma [22, 23] para posteriormente realizar un etiquetado manual de las zonas de interés de las imágenes.

Después se hizo un aumento de datos creando diez imágenes nuevas por cada imagen ya etiquetada. Finalmente, se realizó una reducción de dimensionalidad aplicando el método de "Eigenfaces" basados en el análisis de componentes principales (PCA) [30, 31]. En la parte de prueba, a una nueva imagen en la entrada se le aplica la mejora de contraste y su proyección en el espacio de las "Eigenfaces" para poder realizar su comparación mediante el algoritmo de regresión de "K-NN ponderado".

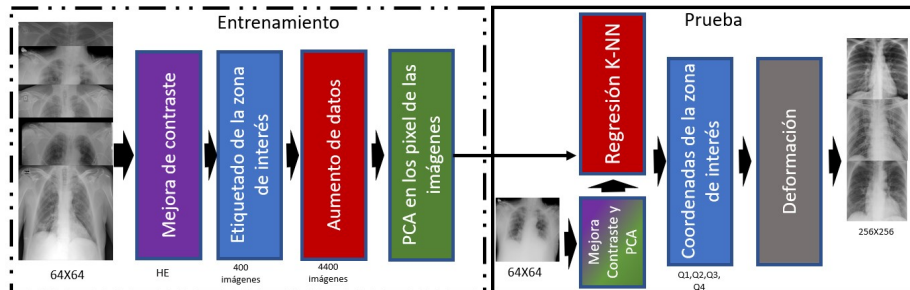


Fig. 2. Descripción del Algoritmo Localizador de Pulmones. En la entrada de la etapa de prueba se encuentra un ejemplo de radiografía y a la salida se tienen la región de interés ya extraída.




Fig. 3. Coordenadas Q1, Q2, Q3 y Q4 en una radiografía.

El objetivo es encontrar las imágenes que sean más parecidas. Las coordenadas de las zonas de interés de dichas imágenes serán utilizadas en la regresión para predecir las coordenadas de la imagen en la entrada, todo esto sucede de manera automática. Ya con las coordenadas calculadas, se utiliza la operación de deformación (Warping) y la interpolación para construir la nueva imagen, que solo contiene la región de interés, a partir de la imagen de entrada.

2.1. Ecuación del histograma

La ecualización del histograma (HE) es una técnica de procesamiento de imágenes que tiene como objetivo mejorar el contraste de una imagen al redistribuir los valores de los píxeles. Esta técnica se basa en la idea de que una distribución uniforme de valores de intensidad en una imagen proporciona una mejor representación visual de la misma.

Para lograr la ecualización del histograma, se calcula el histograma de la imagen original para obtener una representación gráfica de la distribución de los valores de intensidad. Después, se determina una función de transformación que redistribuye los valores de intensidad para lograr una distribución más uniforme. Esta función se aplica a la imagen original para obtener una versión ecualizada del histograma que presenta un mejor contraste.




Fig. 4. Secuencia para la localización de los puntos Q, primero Q1 es localizado, después Q2 para que Q3 y Q4 aparezcan en la recta perpendicular que cruza por el punto medio de la recta Q1Q2. Finalmente, Q3 y Q4 son ajustados.

La ecualización del histograma es una técnica ampliamente utilizada en el procesamiento de imágenes y ha demostrado ser efectiva para mejorar la calidad visual de imágenes en una variedad de aplicaciones.

2.2. Etiquetado de coordenadas para la etapa de entrenamiento

Cada una de las imágenes seleccionadas para esta etapa necesita ser etiquetada manualmente con un arreglo de coordenadas que delimita la zona de interés de los pulmones. Estos puntos se convertirán en las nuevas características que el K-NN ponderado utiliza para su predicción de las imágenes de prueba. El arreglo de coordenadas puede verse en la figura 3, se trata de 4 puntos Q1 (x_1, y_1), Q2 (x_2, y_2), Q3 (x_3, y_3) y Q4 (x_4, y_4). Q1 y Q2 representan el largo de los pulmones y Q3 y Q4 el ancho de los mismos. El proceso del etiquetado puede verse en la figura 4.

Primero se localiza manualmente el punto Q1 en la parte superior de los pulmones, utilizando la columna vertebral como referencia. Posteriormente, Q2 es colocado en la parte inferior de los pulmones. Cuando Q1 y Q2 están colocados automáticamente aparece una recta que los une, en el punto medio de esta recta se coloca una recta perpendicular que contiene a los puntos Q3 y Q4. Estos últimos dos están limitados a solo moverse en la recta perpendicular y pueden tener una distancia diferente al punto medio de la recta Q1Q2, debido a que los pulmones no son simétricos entre ellos.

2.3. Aumento de datos

Esta técnica es utilizada en muchas tareas del aprendizaje de máquina como la clasificación de imágenes para incrementar una base de datos limitada y evitar el sobreajuste [28, 29]. Para nuestro algoritmo, existe una gran cantidad de imágenes en la base de datos utilizada [24, 25].

Sin embargo, con el objetivo de tener una distribución normal en los valores de las coordenadas de la región de interés, se optó por crear radiografías artificiales basadas en las imágenes previamente ya etiquetadas utilizando operaciones de traslación y rotación. Primeramente es necesario definir el rango para las operaciones de las imágenes, para la rotación fue de -10° a 10° (sugerido por [25]) y para la traslación fue de -5 a 5 píxeles, estos valores fueron calculados analizando las coordenadas de las 400 imágenes originales.




Fig. 5. Ejemplo de imágenes artificiales durante el aumento de datos.




Fig. 6. Imágenes de ejemplo con sus regiones de interés ya extraídas.

Después se crearon 10 imágenes artificiales por cada imagen original tomando valores completamente aleatorios que estén dentro del rango predefinido. Las operaciones se aplicaron a la imagen y también a sus coordenadas de la zona de interés. En total la base de datos del ALP contiene 4400 imágenes con una distribución normal en las coordenadas de su arreglo de puntos. En la figura 5 puede verse un ejemplo de las imágenes artificiales creadas junto con su arreglo de puntos.

2.4. Regresión para calcular las coordenadas de los pulmones

Como se ve en la figura 2, para la etapa de prueba se tiene una nueva imagen a la que se le desea obtener su región de interés. Para esta parte y de manera automática, a la imagen de prueba se le aplica la mejora de contraste y reducción de características mediante su proyección en las “Eigenfaces”. Los pesos obtenidos en la proyección se utilizan en el “K-NN ponderado” para encontrar los vecinos más parecidos mediante la distancia euclidiana del espacio de las “Eigenfaces”.

Ya conociendo los vecinos más cercanos se puede realizar una regresión utilizando las coordenadas de las regiones de interés de dichos vecinos para predecir las coordenadas de los pulmones de la imagen de prueba. Las ecuaciones de regresión (1 y 2) se tienen que utilizar para cada coordenada ya sea x o y de cada punto Q hasta que todo el arreglo de puntos (Q1, Q2, Q3 y Q4) se complete. Las ecuaciones se describen abajo:

$$x_i = \frac{1}{k} \sum_{i=1}^k x_{ni}, \quad (1)$$




Fig. 7. Imagen de salida (Izquierda) como la combinación lineal de la matriz de Eigenfaces Q (medio) y la imagen de entrada más la cara media (derecha).

$$y_i = \frac{1}{k} \sum_{i=1}^k y_{ni}. \quad (2)$$

2.5. Image Warping

En el contexto del procesamiento de imágenes y visión por computadora, el término “Warping” se refiere a una transformación geométrica que se aplica a una imagen para cambiar su forma o perspectiva. La técnica de Warping se basa en la aplicación de una función de transformación a cada uno de los píxeles de la imagen original.

Esta función de transformación puede ser lineal o no lineal, y puede ser definida por diferentes parámetros dependiendo del tipo de transformación deseada. Algunas técnicas de Warping comunes incluyen la homografía, la transformación afín y la transformación de Fourier [33]. Después de tener las coordenadas mediante la regresión, se utiliza la operación Warping para la extracción de la zona de interés.

En la figura 6 pueden verse ejemplos de las imágenes originales y la obtención automática de sus coordenadas de la región de interés (puntos rojos) y las coordenadas que utiliza la operación Warping (puntos azules). En el lado derecho puede verse la imagen de salida del ALP.

3. Reducción y selección de características

Después utilizar el ALP en todo el banco de datos para extraer todas las regiones de interés, estas nuevas imágenes recibirá otro preprocesamiento antes de entrar a algún algoritmo clasificador. Para nuestro trabajo proponemos el uso de las Eigenfaces [30, 31] como método de reducción de características.

Además, incluimos el análisis estadístico de las mismas obtenido mediante el discriminante lineal de Fisher. Estos dos métodos en conjunto garantizan la obtención de un número pequeño de características que mejor discriminan las clases para una clasificación.

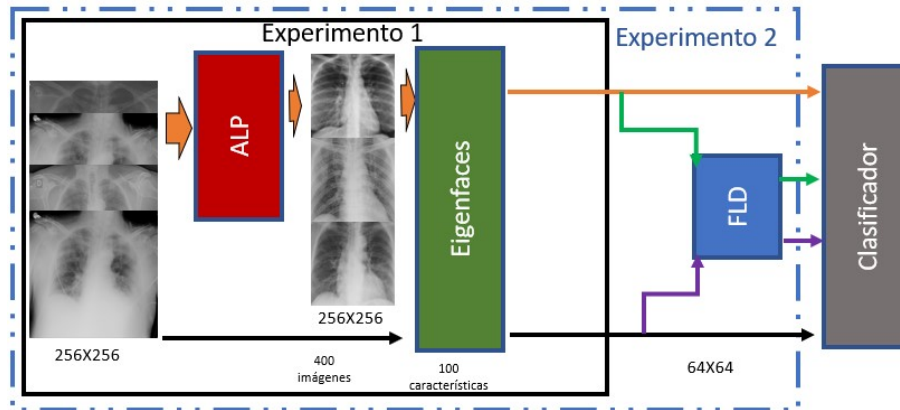


Fig. 8. Diagrama acerca de los dos experimentos. Cada flecha que llega al clasificador es una métrica de precisión y se realizará una comparación de todas.

3.1. Eigenfaces

El método de las Eigenfaces fue creado primeramente por Turk y Pentland [30] y por Sirovich y Kirby [31]. Este método está basado en el análisis de componentes principales (PCA) y su objetivo es la reducción de la dimensionalidad de las imágenes en el banco de datos [32]. Debido a que cada píxel se convierte en una dimensión o variable para analizar y que tenemos imágenes con una resolución de 256x256, cada imagen demandaría un largo tiempo de procesamiento.

Cada Eigenface es una imagen que muestra una estructura de rasgos o patrones que son comunes en el conjunto de imágenes utilizado. Estas Eigenfaces son ordenadas de acuerdo a la varianza de las imágenes de entrada, pueden ser utilizadas para reconstruir cualquier imagen como una combinación lineal de ellas y representarla también en un espacio de menor dimensión.

En la figura 7 puede verse la ecuación de las Eigenfaces y la matriz Q de Eigenfaces. Por otro lado, es necesario que las imágenes de entrada tengan condiciones de luz y ángulo semejantes. Por esta razón el ALP es utilizado antes como una manera de normalizar las radiografías.

3.2. El discriminante lineal de Fisher para la selección de características

El discriminante lineal de Fisher (FLD) busca encontrar una proyección lineal de las características que maximice la separación entre las clases del banco de datos. Esta proyección se realiza evaluando las características una a una y analiza que las medias de las observaciones de cada clase estén lo más alejadas posibles y que las varianzas dentro de cada clase sean lo más pequeñas posibles. Utilizando este análisis se pueden seleccionar las características obtenidas del método de las Eigenfaces que mejor discriminan las clases del conjunto de datos [34].




Fig. 9. Valores de precisión variando el numero de características. K-NN ponderado (Línea roja) y MLP (Línea azul).




Fig. 10. Topología del MLP.

El FLD ha sido usado en traba como en [35], es denotado como J y su fórmula se encuentra en la ecuación 3:

$$J_i = \frac{(\mu_{ic_0} - \mu_{ic_1})^2}{\sigma_{ic_0}^2 + \sigma_{ic_1}^2}. \tag{3}$$

4. Resultados experimentales

Para esta sección, se dividieron los resultados en dos experimentos. El primero fue la comparación del banco de datos original contra el banco de imágenes ya normalizadas. Para ambos bancos se utilizaron las Eigenfaces como método de reducción de dimensiones. El segundo experimento implementará la selección de características para los dos bancos de imágenes previamente mencionados.

Tabla 1. Resultados del K-NN ponderado para diferentes valores de K.

Parámetro K	Banco normalizado	Banco no alineado
3	86.29 %	73.76 %
4	87.17 %	74.48 %
5	87.31 %	75.36 %
6	87.60 %	75.80 %
7	87.9 %	75.80 %
8	88.04 %	75.80 %
9	88.19 %	76.23 %
10	88.19 %	76.96 %
11	88.48 %	77.25 %
12	88.48 %	77.25 %

Dando un total de cuatro métricas de precisión en la clasificación, las cuales serían: sin normalizar y sin selección de características, sin normalizar y con selección de características, normalizadas sin selección de características y normalizadas con selección de características. Se utilizaron los algoritmos de K-NN ponderado y MLP como clasificadores. En la figura 8 pueden verse ambos experimentos y los diferentes bloques que los conforman.

4.1. Preparación para el primer experimento

Se utilizaron 1345 (256X256) imágenes de neumonía y otras 1345 (256X256) de normal, a todas estas imágenes se les extrajo la región de interés formando el banco de imágenes normalizado usando el ALP. Las imágenes se dividieron en 2000 imágenes para el entrenamiento, 1000 de cada clase. Para la etapa de prueba se tomaron 700 imágenes, 350 por cada clase. Para seleccionar un número adecuado de características, se realizaron pruebas variando el número de características en ambos clasificadores desde 10 características hasta 1000.

En la figura 9 se muestra el gráfico que representa el número de características contra el valor de precisión de cada clasificador. Con esto puede verse que para ambos clasificadores 100 características son suficientes para alcanzar el máximo valor. Para el MLP se utilizaron 3 capas ocultas con 500 neuronas cada una. En la figura 10 se puede observar la topología completa del MLP usado.

4.2. Resultados y discusión del primer experimento

Para el K-NN ponderado se utilizaron diferentes valores para el parámetro K en la tabla 1 puede verse los resultados para ambos bancos de datos. Puede verse que el mejor valor de K es 11, además el banco de datos normalizado tiene mejores resultados. Para el MLP el banco original obtuvo un 79.81 % de precisión y el alineado obtuvo un 88.64 %. Para ambos clasificadores es mejor utilizar las imágenes alineadas que las originales.

Tabla 2. Resultados de K-NN ponderado para diferentes valores de K.

K-NN ponderado (banco alineado)	
Sin selección	Selección de características
88.48 %	89.62 %
K-NN ponderado (banco no alineado)	
Sin selección	Selección de características
77.25 %	79.21 %
MLP (banco alineado)	
Sin selección	Selección de características
88.64 %	90.08 %
MLP (banco no alineado)	
Sin selección	Selección de características
79.81 %	80.32 %

Tabla 3. Resultados de K-NN ponderado y MLP para la validación cruzada.

Clasificador	K-NN ponderado	MLP
Test 1	88.62\ %	90.08\ %
Test 2	88.77\ %	90.08\ %
Test 3	89.79\ %	90.22\ %
Test 4	89.79\ %	91.24\ %
Test 5	89.65\ %	91.24\ %
Promedio	89.32\ %	91.10\ %
Desviación estándar	0.577\ %	0.577\ %

4.3. Preparación para el segundo experimento

Durante el segundo experimento, el FLD fue aplicado a las 1000 características de la figura 9 y se obtuvieron las mejores 100 características de ambos bancos para la clasificación. Las 100 características seleccionadas mediante el FLD se compararon con las obtenidas mediante las Eigenfaces. Los clasificadores del primer experimento fueron usados en este también.

4.4. Resultados y discusión para el segundo experimento

En la tabla 2 se pueden ver todas las métricas de precisión para los dos clasificadores. Primeramente el banco de datos normalizado obtiene los valores más altos. Además la selección de características logró incrementar el valor de precisión, ya que las características con poca relevancia para la clasificación fueron excluidas.

4.5. Resultados adicionales

El conjunto de datos alineados fue utilizado para realizar una validación cruzada para poder observar la consistencia del conjunto de algoritmos propuestos en este trabajo. En la tabla 3 pueden verse los resultados de las 5 pruebas realizadas además del promedio y la desviación estándar para cada clasificador.

5. Conclusiones y trabajo futuro

En este trabajo se introdujo un problema sobre la alineación de las región de interés en la radiografías de tórax. Nuestro método propuesto es un conjunto de algoritmos que toman las regiones de interés de las imágenes y logra normalizarlas además de representarlas con un número menor de características.

A lo largo de este trabajo pudo verse que la normalización de imágenes y la selección de características pueden generar mejores resultados en la clasificación. También puede verse que al usar dichas técnicas en conjunto generan una propuesta consistente, resultado de la validación cruzada. La normalización de imágenes genera que el método de las Eigenfaces, basado en el PCA, otorgue mejores resultados, ya que ahora la región de interés aparece en el mismo ángulo y la misma iluminación en el conjunto de datos. El FLD nos otorga características con mejores capacidades para la clasificación de las clases.

Nuestra propuesta logra alcanzar valores de precisión aceptables frente a otros trabajos del estado del arte sin la necesidad de utilizar técnicas basadas en CNNs. Para el trabajo futuro, el ALP puede ser utilizado en otras bases de datos y para la detección de otras enfermedades pulmonares, además de que otros clasificadores pueden utilizar las imágenes normalizadas o las mejores características que el FLD pueda dar para representar el conjunto de datos.

Referencias

1. World Health Organization: Pneumonia (2023) <http://www.who.int/es/news-room/fact-sheets/detail/pneumonia>
2. Alzahrani, S. A., Al-Salamah, M. A., Al-Madani, W. H., Elbarbary, M. A.: Systematic review and meta-analysis for the use of ultrasound versus radiology in diagnosing of pneumonia. *Critical Ultrasound Journal*, vol. 9, no. 1 (2017) doi: 10.1186/s13089-017-0059-y
3. Amatya, Y., Rupp, J., Russell, F. M., Saunders, J., Bales, B., House, D. R.: Diagnostic use of lung ultrasound compared to chest radiograph for suspected pneumonia in a resource-limited setting. *International Journal of Emergency Medicine*, vol. 11, no. 1 (2018) doi: 10.1186/s12245-018-0170-2
4. Moberg, A. B., Taléus, U., Garvin, P., Fransson, S. G., Falk, M.: Community-acquired pneumonia in primary care: clinical assessment and the usability of chest radiography. *Scandinavian Journal of Primary Health Care*, vol. 34, no. 1, pp. 21–27 (2016) doi: 10.3109/02813432.2015.1132889
5. Ticinesi, A., Lauretani, F., Nouvenne, A., Mori, G., Chiussi, G., Maggio, M., Meschi, T.: Lung ultrasound and chest x-ray for detecting pneumonia in an acute geriatric ward. *Medicine*, vol. 95, no. 27, pp. e4153 (2016) doi: 10.1097/md.0000000000004153
6. Niederman, M.: *Community-acquired pneumonia annals of internal medicine*. 2nd edition (2009)
7. Salvatore, C., Interlenghi, M., Monti, C. B., Ippolito, D., Capra, D., Cozzi, A., Schiaffino, S., Polidori, A., Gandola, D., Alì, M., Castiglioni, I., Messa, C., Sardanelli, F.: Artificial intelligence applied to chest X-ray for differential diagnosis of COVID-19 pneumonia. *Diagnostics*, vol. 11, no. 3, pp. 530 (2021) doi: 10.3390/diagnostics11030530
8. Qin, C., Yao, D., Shi, Y., Song, Z.: Computer-aided detection in chest radiography based on artificial intelligence: a survey. *BioMedical Engineering OnLine*, vol. 17, no. 1 (2018) doi: 10.1186/s12938-018-0544-y

9. Ghaderzadeh, M., Aria, M., Asadi, F.: X-Ray equipped with artificial intelligence: Changing the COVID-19 diagnostic paradigm during the pandemic. *BioMed Research International*, vol. 2021, pp. 1–16 (2021) doi: 10.1155/2021/9942873
10. Amatya, Y., Rupp, J., Russell, F. M., Saunders, J., Bales, B., House, D. R.: Diagnostic use of lung ultrasound compared to chest radiograph for suspected pneumonia in a resource-limited setting. *International Journal of Emergency Medicine*, vol. 11, no. 1 (2018) doi: 10.1186/s12245-018-0170-2
11. Cleophas, T. J., Zwinderman, A. H.: *Machine learning in medicine*. vol. 2, Springer (2013)
12. Ertel, W.: *Introduction to artificial intelligence*. Springer International Publishing (2017) doi: 10.1007/978-3-319-58487-4
13. Changawala, V., Sharma, K., Paurwala, M.: Averting from convolutional neural networks for chest X-Ray image classification. *IEEE International Conference on Signal Processing*, pp. 14–17 (2021) doi: 10.1109/SPICSCON54707.2021.9885316
14. Liu, W., Zheng, Y., Zhou, X., Chen, Q.: Axis orbit recognition of the hydropower unit based on feature combination and feature selection. *Sensors*, vol. 23, no. 6, pp. 2895 (2023) doi: 10.3390/s23062895
15. Lv, C., Lu, Y., Lu, M., Feng, X., Fan, H., Xu, C., Xu, L.: A classification feature optimization method for remote sensing imagery based on fisher score and mRMR. *Applied Sciences*, vol. 12, no. 17, pp. 8845 (2022) doi: 10.3390/app12178845
16. Hamza, A., Attique Khan, M., Wang, S. H., Alhaisoni, M., Alharbi, M., Hussein, H. S., Alshazly, H., Kim, Y. J., Cha, J.: COVID-19 classification using chest X-ray images based on fusion-assisted deep Bayesian optimization and Grad-CAM visualization. *Frontiers in Public Health*, vol. 10 (2022) doi: 10.3389/fpubh.2022.1046296
17. Nillmani, Sharma, N., Saba, L., Khanna, N. N., Kalra, M. K., Fouda, M. M., Suri, J. S.: Segmentation-based classification deep learning model embedded with explainable artificial intelligence for COVID-19 detection in chest X-ray scans. *Diagnostics*, vol. 12, no. 9, pp. 2132 (2022) doi: 10.3390/diagnostics12092132
18. Gazda, M., Plavka, J., Gazda, J., Drotar, P.: Self-Supervised Deep Convolutional Neural Network for Chest X-Ray Classification. *IEEE Access*, vol. 9, pp. 151972–151982 (2021) doi: 10.1109/access.2021.3125324
19. Do, T. N., Le, V. T., Doan, T. H.: SVM on top of deep networks for COVID-19 detection from chest X-ray images. *Journal of information and communication convergence engineering*, vol. 20, no. 3, pp. 219–225 (2022) doi: 10.56977/jicce.2022.20.3.219
20. El-Kenawy, E. S. M., Mirjalili, S., Ibrahim, A., Alrahmawy, M., El-Said, M., Zaki, R. M., Eid, M. M.: Advanced meta-heuristics, convolutional neural networks, and feature selectors for efficient COVID-19 X-Ray chest image classification. *IEEE Access*, vol. 9, pp. 36019–36037 (2021) doi: 10.1109/access.2021.3061058
21. Ridzuan, M., Bawazir, A. A., Navarette, I. G., Almakky, I., Yaqub, M.: Self-supervision and multi-task learning: challenges in fine-grained COVID-19 multi-class classification from Chest X-rays (2022) doi: 10.48550/ARXIV.2201.06052
22. Gonzales, R. C., Woods, R.: *Digital image processing*. Pearson, 4 ed (2018)
23. Moeslund, T. B.: *Introduction to video and image processing*. Springer London (2012) doi: 10.1007/978-1-4471-2503-7
24. Chowdhury, M. E. H., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M. A., Mahbub, Z. B., Islam, K. R., Khan, M. S., Iqbal, A., Emadi, N. A., Reaz, M. B. I., Islam, M. T.: Can AI help in screening viral and COVID-19 pneumonia? *IEEE Access*, Institute of Electrical and Electronics Engineers (IEEE), vol. 8, pp. 132665–132676 (2020) doi: 10.1109/access.2020.3010287
25. Rahman, T., Khandakar, A., Qiblawey, Y., Tahir, A., Kiranyaz, S., Abul Kashem, S. B., Islam, M. T., Al Maadeed, S., Zughhaier, S. M., Khan, M. S., Chowdhury, M. E. H.:

- Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images. *Computers in Biology and Medicine*, vol. 132, pp. 104319 (2021) doi: 10.1016/j.combiomed.2021.104319.
26. Muljo, H. H., Pardamean, B., Purwandari, K., Cenggoro T. W.: Improving lung disease detection by joint learning with COVID-19 radiography database. *Communications in Mathematical Biology and Neuroscience*, vol. 2022
 27. Islam, N., Ebrahimzadeh, S., Salameh, J. P., Kazi, S., Fabiano, N., Treanor, L., Absi, M., Hallgrimson, Z., Leeftang, M. M., Hooft, L., van der Pol, C. B., Prager, R., Hare, S. S., Dennie, C., Spijker, R., Deeks, J. J., Dinnes, J., Jenniskens, K., Korevaar, D. A., Cohen, J. F., et al.: Thoracic imaging tests for the diagnosis of COVID-19. *Cochrane Database of Systematic Reviews*, vol. 2021, no. 3 doi: 10.1002/14651858.cd013639.pub4
 28. Mikolajczyk, A., Grochowski, M.: Data augmentation for improving deep learning in image classification problem. *International Interdisciplinary PhD Workshop IEEE* (2018) doi: 10.1109/iiphdw.2018.8388338
 29. Connor, S., Khoshgoftaar, T.: A survey on image data augmentation for deep learning. *Journal of Big Data*, vol. 6, no. 1 (2019) doi: 10.1186/s40537-019-0197-0
 30. Turk, M., Pentland, A.: Eigenfaces for recognition. *Journal of Cognitive Neuroscience*, vol. 3, no. 1, pp. 71–86 (1991) doi: 10.1162/jocn.1991.3.1.71
 31. Kirby, M., Sirovich, L.: Application of the Karhunen-Loeve procedure for the characterization of human faces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 12, no. 1, pp. 103–108 (1990) doi: 10.1109/34.41390
 32. Jolliffe, I.: *Principal component analysis*. Springer Series in Statistics (2002)
 33. Szeliski, R.: *Computer vision: Algorithms and applications*, 2nd ed., Springer (2022)
 34. Thalles, S.: *An illustrative introduction to Fisher's Linear Discriminant* (2023) <https://sthalles.github.io/fisher-linear-discriminant/>
 35. Ibis, E.: *Sistema de aprendizaje automático para la detección de neumonía*, M. S. thesis (2022)

Metadata of the chapter that will be visualized in SpringerLink

Book Title	Pattern Recognition	
Series Title		
Chapter Title	Synergizing Chest X-ray Image Normalization and Discriminative Feature Selection for Efficient and Automatic COVID-19 Recognition	
Copyright Year	2023	
Copyright HolderName	The Author(s), under exclusive license to Springer Nature Switzerland AG	
Author	Family Name	Ayala-Raggi
	Particle	
	Given Name	Salvador Eugenio
	Prefix	
	Suffix	
	Role	
	Division	
	Organization	Benemérita Universidad Autónoma de Puebla
	Address	Puebla, Mexico
	Email	saraggi@gmail.com
Corresponding Author	Family Name	Picazo-Castillo
	Particle	
	Given Name	Angel Ernesto
	Prefix	
	Suffix	
	Role	
	Division	
	Organization	Benemérita Universidad Autónoma de Puebla
	Address	Puebla, Mexico
	Email	a.picazo.2505@gmail.com
Author	Family Name	Barreto-Flores
	Particle	
	Given Name	Aldrin
	Prefix	
	Suffix	
	Role	
	Division	
	Organization	Benemérita Universidad Autónoma de Puebla
	Address	Puebla, Mexico
	Email	
Author	Family Name	Portillo-Robledo
	Particle	
	Given Name	José Francisco
	Prefix	
	Suffix	

Role
Division
Organization Benemérita Universidad Autónoma de Puebla
Address Puebla, Mexico
Email

Abstract

This paper presents a method for COVID-19 recognition based on the automatic localization and further pose and scale normalization of the region of interest, in this case lungs, in chest radiographs using PCA and weighted K-NN regression. Our proposed technique involves estimating by interpolation the corner positions of the region of interest, and mapping the image within that located region to a standardized fixed size template. The aim is to make all training images from a dataset similar in terms of position, angular pose, scale, and contrast, i.e. to align them. Subsequently, the eigenfaces method is used to obtain a reduced set of principal features of the normalized images. From these PCA-derived features, the ones with the best between class discrimination capability are selected by using the Fisher criterion. Our results show that the combination of our effective lung region alignment technique with the proper selection and weighting of the most discriminant PCA features is enough to achieve maximum accuracies of 95.2% and 97% in the classification of COVID-19 radiographs when traditional classifiers, such as weighted K-NN and MLP respectively, are used. Our results show that in contrast to convolutional neural networks, a simpler technique can be used to obtain similar results for classification.

[CODE: <https://github.com/picazo07/LFA.git>]

Keywords
(separated by '-')

K-Nearest Neighbors - Image Classification - Fisher Discriminant Criterion - COVID-19



Synergizing Chest X-ray Image Normalization and Discriminative Feature Selection for Efficient and Automatic COVID-19 Recognition

Salvador Eugenio Ayala-Raggi, Angel Ernesto Picazo-Castillo^(✉),
Aldrin Barreto-Flores, and José Francisco Portillo-Robledo

Benemérita Universidad Autónoma de Puebla, Puebla, Mexico
a.picazo.2505@gmail.com

Abstract. This paper presents a method for COVID-19 recognition based on the automatic localization and further pose and scale normalization of the region of interest, in this case lungs, in chest radiographs using PCA and weighted K-NN regression. Our proposed technique involves estimating by interpolation the corner positions of the region of interest, and mapping the image within that located region to a standardized fixed size template. The aim is to make all training images from a dataset similar in terms of position, angular pose, scale, and contrast, i.e. to align them. Subsequently, the eigenfaces method is used to obtain a reduced set of principal features of the normalized images. From these PCA-derived features, the ones with the best between class discrimination capability are selected by using the Fisher criterion. Our results show that the combination of our effective lung region alignment technique with the proper selection and weighting of the most discriminant PCA features is enough to achieve maximum accuracies of 95.2% and 97% in the classification of COVID-19 radiographs when traditional classifiers, such as weighted K-NN and MLP respectively, are used. Our results show that in contrast to convolutional neural networks, a simpler technique can be used to obtain similar results for classification.

[AQ1](#)[AQ2](#)[AQ3](#)[AQ4](#)

[CODE: <https://github.com/picazo07/LFA.git>]

Keywords: K-Nearest Neighbors · Image Classification · Fisher Discriminant Criterion · COVID-19

1 Introduction

COVID-19 is a respiratory disease caused by the SARS-CoV-2 virus. It is primarily transmitted through respiratory droplets and can cause symptoms such as fever, cough, and difficulty breathing. In addition to laboratory tests, chest radiographs are used as a screening tool to evaluate potential signs of pulmonary infection caused by the virus. These images can exhibit characteristic patterns, such as opacities or infiltrates, which can assist doctors in diagnosing and monitoring the disease [6]. Furthermore, various studies have demonstrated the effectiveness of chest radiographs in detecting COVID-19 [1, 2, 23, 27, 38].

© The Author(s), under exclusive license to Springer Nature Switzerland AG 2023
H. Lu et al. (Eds.): ACPR 2023, LNCS 14407, pp. 1–14, 2023.
https://doi.org/10.1007/978-3-031-47637-2_17

Currently, there are datasets available that contain labeled radiographs, which can be utilized to train various machine learning algorithms [2]. The construction of these banks has been a collaborative effort involving institutions and medical experts in the field [26,30,33]. However, the challenge lies in the lack of uniformity in the region of interest (lungs) within these images. Some radiographs contain unwanted or irrelevant information for classification, such as additional body parts or objects covering the chest. This can adversely affect the precision metrics of classification algorithms [5,10].

In this work, we aim to demonstrate the hypothesis that aligning the region of interest in both the training images and the test image, such that the anatomical structures within the lungs are positionally consistent across all images, can enable simple and conventional classification methods like K-NN or MLP to achieve better accuracy results, provided that a reliable feature reduction method like PCA is employed in conjunction with a feature selection process based on their discriminatory capability.

To this end, we propose applying two consecutive processes. The first process involves the detection and normalization of the lung region, ensuring that the images within the lung region exhibit the same alignment, location, scale, and improved contrast as much as possible. In the second process, the “Eigenfaces” method (PCA) will be applied to the aligned regions to obtain a reduced set of statistically independent features. Finally, based on the Fisher criterion [35], we propose performing a selection of the features that best discriminate between classes. Using this set of optimal features and a traditional classifier such as K-NN or MLP, the classification accuracy will be measured.

This work comprises seven essential parts. Section 1 introduces the research context, discussing related work and the database. Section 2 outlines the “Lung Finder Algorithm” (LFA) utilized for normalization. Section 3 presents the “Eigenfaces” and Fisher linear discriminant theory, along with our feature weighting approach for normalized image features. Section 4 describes the experimental setup, including the dataset and parameter settings. Section 5 reveals and analyzes the results, demonstrating the performance of our methodology using weighted K-Nearest Neighbors (K-NN) and the Multilayer Perceptron (MLP) [9]. Section 6 delves into result discussion, exploring trends and implications. Lastly, Sect. 7 offers conclusions drawn from the findings and outlines possible future research directions.

AQ5

1.1 Related Work

Currently, various methodologies have been developed for classification of chest radiographs, as evidenced in previous studies [4,11,13,17,28,31,37]. These methodologies make use of deep learning algorithms or traditional machine learning classifiers [7,8], and have reported high levels of classification accuracy, greater than 96%. However, the architectures employed in these algorithms still face challenges in achieving a reliable classification of COVID-19 [32], as their accuracy decreases when tested with other datasets different from those used for training. This raises the need of exploring new proposals for normalizing and

aligning the lungs region before classifying, instead of just facing the problem by training classifiers like CNNs with a large number of different datasets, to cope with the bias imposed by a particular one. Efficient non CNN-based works have been proposed too, as in [3], where a Multilayer Perceptron (MLP) and an architecture based on image involution were used, which proposes kernels similar to CNNs but shares their weights dynamically in all dimensions, thus reducing the number of multiplications necessary for the calculations. The former obtained a maximum classification accuracy of 98.31%. Feature selection has proven to be effective in increasing classification accuracy in other works, as observed in a study on [20] which used support vector machines to recognize the orbit axis of the sensors, as in another study [29] where it was also possible to classify the frequencies of an encephalogram. Furthermore, in a work carried out by Chengzhe et al. [21], the K-NN algorithm was applied successfully. Several studies have shown that image normalization improves classification results. In a study on kidney radiographs [10], the best results were obtained using CNN and image normalization techniques. Also, in another [19] work, different normalization techniques were used on different types of radiographs to improve image classification. It is important to highlight that the results of our work are not intended to devalue CNNs in image classification, but rather to present an alternative option, and to demonstrate that image alignment and a proper feature selection technique can produce results comparable to the most commonly used algorithms. in the state of the art. In the Table 1 we show the comparison of the different pre-processing methods used in some published works [3, 10, 19–21, 29]

Table 1. Comparison of the different preprocessing methods from related works.

Authors	Image Normalization	Features selection	Classifier	Accuracy
Changawala et al., (2021)	Not Used	Not Used	MLP (Involution)	98.31%
Liu et al., (2023)	Not Used	Used	SVM	100%
Park et al., (2015)	Not Used	Used	SVM	93.5%
Lv et al., (2022)	Not Used	Used	KNN	96.14%
Gadermayr et al., (2017)	Used	Not Used	SVM	97%
Kociolek et al., (2020)	Used	Used	SVM	96%
This Work	Used	Used	KNN/MLP	95.2%/97%

1.2 Data Set of Radiographic Images

The database used for this work was “COVID-19 Radiography Database” [4, 31] from kaggle. This data set was selected because it has been used in other similar works [15, 25]. The content of this data set is 6012 images already labeled as pulmonary opacity (other lung diseases), 1345 as viral pneumonia, 10192 as normal, and finally 3616 as COVID-19.

2 Overview of the Lung Finder Algorithm (LFA)

The goal of this algorithm is to locate the lungs in the radiographs, and it consists of a training and testing stage, as shown in Fig. 1. During the training stage, 400 images from the Pneumonia, COVID-19, and Normal classes were randomly selected from the data set. Histogram equalization (HE) [12, 24] was applied to all images and regions of interest were manually labeled by placing 4 provisional landmarks easily located by a human user. It was agreed that two of them would be located, one in the middle of the cervical vertebrae just at the upper limit of the lungs, and the other also on the spine but below where the lung region ends. The other two provisional landmarks are forced to the user to place them on a imaginary straight line perpendicular to the spine that intersects it just in the middle of the two previous landmarks. These last two landmarks are located in the left and right sides of lung region. Finally, and by using these 4 provisional positions, we compute 4 final and permanent landmarks at the corners of the rectangular lung region. On the other hand, ten new images randomly rotated and displaced were then generated for each labeled image to increase the data set and have an *augmented dataset*. Next, a dimensionality reduction to this set of 4400 images was applied using the “Eigenfaces” method based on Principal Component Analysis (PCA) [18, 39].

During the test stage, and after a contrast improvement (H.E.), a new image is projected to the “Eigenfaces” linear subspace in order to convert it to a compact few dimensions vector which is compared via euclidean distance with each of the 4000 examples contained within the augmented dataset to find k nearest neighbors $k - NN$. The landmarks associated with these k most similar images from the augmented dataset are used to estimate the 4 landmarks of the test image by interpolation. These predicted landmarks are the coordinates of the corners of the lung ROI which can be used to warp the inside region to a standard template of fixed size.

2.1 Coordinates Labeling for the LFA Training Stage

Each of the images selected for this stage requires a manual labeling where the region of interest of the lungs is delimited by a set of coordinates. These points or landmarks become the labels used by a regression weighted K-NN to predict the corner coordinates of the novel image. The coordinates the lung region are shown in Fig. 2, and consist of four points: $Q1(x1,y1)$, $Q2(x2,y2)$, $Q3(x3,y3)$ and $Q4(x4,y4)$. $Q1$ and $Q2$ represent the length of the lungs, while $Q3$ and $Q4$ represent their width. In total, 400 images were labeled manually.

The labeling process is shown in Fig. 3. First, the $Q1$ point at the top of the lungs is manually located, using the spine as reference. The $Q2$ point is then placed at the bottom of the lungs. When the points $Q1$ and $Q2$ are placed, a straight line connecting them automatically appears, and at the midpoint of this line a perpendicular line is drawn containing the points $Q3$ and $Q4$. These last two points are constrained to be placed by the user only along the perpendicular

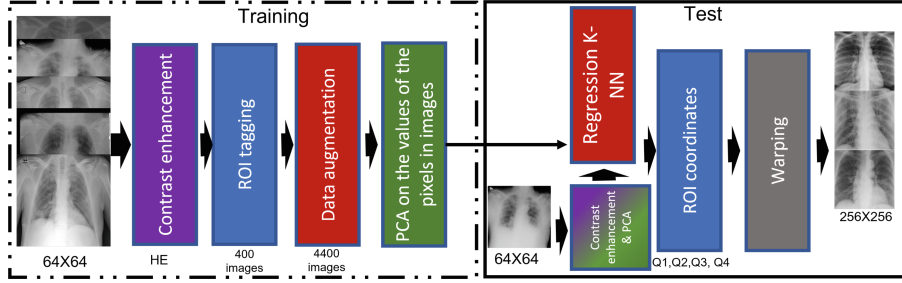


Fig. 1. Lung Finder Algorithm description. During the training phase, 400 images were tagged with their coordinates. PCA was applied to reduce the dimensionality of the images. In the testing phase, an example radiograph is provided as input, and the algorithm extracts the region of interest as the output. During the test phase, the test image is compared with its nearest neighbors to interpolate its coordinates. Finally, the algorithm outputs the extracted region of interest in a new image.




Fig. 2. Example of an array of coordinates Q1, Q2, Q3, and Q4 on a radiograph.

line, and may have a different distance from the midpoint of the Q1Q2 line, due to the fact that the lungs are not symmetrical to each other.

2.2 Data Augmentation

Data augmentation is used in various machine learning tasks, such as image classification, to expand a limited database and avoid overfitting [19, 22, 34]. In the case of our algorithm, we have used a large dataset [4, 31]. However, in order to have a set with ROI coordinates sufficiently varied we decided to generate artificial examples based on a randomly selected set, 400 images extracted from original set. The additional artificial images were generated by producing random translations and rotations of the original images. Ten additional artificial images were created from each of the original 400, resulting in a total of 4400 images. First, it was necessary to define the range of operations on the images. For rotation, we set a range of -10 to 10° , suggested by [31], and for translation a range from -5 to 5 pixels. These values were calculated by analyzing the coordinates of the 400 manually labeled images. In summary, the LFA training set contains 4400 images where the coordinates of the landmarks are normal distributed. Figure 4 shows an example of artificial images with their corresponding landmarks.




Fig. 3. Sequential placement of the points Q. First Q1 is placed, then Q2 so that Q3 and Q4 appear on the perpendicular line that crosses the midpoint of the line Q1Q2. Finally, Q3 and Q4 are adjusted.




Fig. 4. Example of artificial images during data augmentation, applying translation and rotation operations.

2.3 Estimating the Corner Coordinates of the Lung Region by Regression

As shown in Fig. 1, in the test stage a new image is introduced from which it is desired to obtain its region of interest. Contrast enhancement and feature reduction are automatically applied to the test image by projecting it onto the “Eigenfaces”. The weights obtained in this projection are used in the “weighted regression K-NN” algorithm to find the most similar neighbors in the “Eigenfaces” space, using the Euclidean distance. In order to reduce the computational cost, the calculations are performed in a 64×64 resolution.

Once the nearest neighbors have been identified, a regression is performed using the coordinates of the ROIs of these neighbors with the aim of predicting the coordinates of the lungs in the test image. For this, the regression (1) and (2) are used, which are applied to each coordinate, either x or y, of each Q landmark, until completing the entire set of landmarks (Q1, Q2, Q3 and Q4). The regression equations are detailed below

$$x_i = \frac{1}{k} \sum_{i=1}^k x_{ni} \quad (1)$$

$$y_i = \frac{1}{k} \sum_{i=1}^k y_{ni} \quad (2)$$

2.4 Image Warping

Once the coordinates are obtained through regression, a Warping operation [36] is used to extract the region of interest. In Fig. 5, examples of different test radiographs from the data set are presented along with their automatically estimated ROI coordinates of provisional landmarks (red dots). The calculated coordinates are geometrically transformed to obtain the corners of the ROI (final landmarks depicted as blue dots) that are used in the Warping operation towards a standard fixed size template. On the right side of each image the normalized image resulting from the LFA is shown.




Fig. 5. Two examples of new images with their estimated ROI coordinates used to warp the inside region towards a fixed and normalized template. (Color figure online)

3 Feature Reduction and Selection

After using the LFA on all radiographs in the data set to extract all regions of interest, these new images undergo additional preprocessing before being processed by a classifying algorithm. For our work, we propose the use of [18,39] Eigenfaces as a feature reduction method. In addition, we incorporated a statistical analysis of these features using Fisher's linear discriminant in order to preserve only the most discriminating features and weighing each of them according to their power of discrimination between classes. Together these two methods ensure obtaining a reduced number of discriminant features suitable for efficient classification using traditional classifiers.

3.1 Eigenfaces for Dimensionality Reduction

Eigenfaces [18,39] is based on principal component analysis (PCA) and its objective is to reduce the dimensionality of the images in the [16] dataset. Because each pixel becomes a dimension or feature to be analyzed, processing 256×256 images can be time consuming. On the other hand, a large number of features, in comparison to a smaller number of training examples, could produce missclassification when euclidean distance based approaches as k-NN are used.

The resulting eigenfaces are sorted according to the greater variances of the training set, and can be used to reconstruct every image in the training set as a linear combination of them. Because the greatest amount of variance is

concentrated in the first eigenfaces, we can use only a few number of them to efficiently represent all the training images and even novel ones. Thus, every normalized image from the training set can be represented with this compact set of features. Figure 6 shows the Eigenfaces equation, and the matrix Q which columns are the Eigenfaces. The *eigenfaces* method works better and is capable of concentrating more variance in a less number of eigenfaces when training images are more similar. In our case, the normalized images are more similar to each other than the original images from the dataset. For this reason, the number of useful PCA features is necessarily reduced when using the proposed LFA.

The diagram shows a visual representation of the Eigenfaces equation. On the left is a grayscale image of a human chest. An arrow points from this image to the equation $\bar{X} = QX + \Psi$. Above the equation, a row of five grayscale images represents the columns of matrix Q , which are the Eigenfaces. A bracket underneath these five images points to the Q in the equation. To the right of the equation is another grayscale image representing the mean image Ψ , with an arrow pointing from it to the Ψ in the equation.

Fig. 6. Reconstructed image (left) is computed as a linear combination of the columns of matrix Q (in the middle) plus the mean image (right)

3.2 Using the Fisher Discriminant to Reduce the Number of Useful Features

Fisher discriminant criterion also known as Fisher ratio FR has been used in Linear Discriminant Analysis for finding a linear projection of features that maximizes the separation between classes. Typically, only one important feature survives this process in two classes problems. However, since the PCA features are to some degree independent, we can use, in a naive fashion, the fisher ratio as a measure of separation between classes for a each feature.

This process is done by evaluating each feature individually, and making sure that the means of the observations in each class are as far apart as possible, while the variances within each class are as small as possible. Using this analysis, it is possible to select a number greater than 2 of those features obtained by the Eigenfaces method that best discriminate the classes in the data set [35]

The FR has been used in works such as the one mentioned in [14], and we denoted it as J . The FR formula is found in Eq. 3 (Fig. 7).

[AQ6](#)

$$J_i = \frac{(\mu_{ic_0} - \mu_{ic_1})^2}{\sigma_{ic_0}^2 + \sigma_{ic_1}^2} \quad (3)$$




Fig. 7. Example of frequency distributions for each class. The discriminative capability of a feature can be visually assessed by the separation between the means of the histograms. The pair of histograms on the right shows a greater separation, indicating higher discrimination between classes. Conversely, the pair of histograms on the left exhibits lower discrimination.

3.3 The Fisher Ratio as a Weight for Each Feature

We propose to use the FR value as a weigh for each feature, in such a way that those features that possess a greater capacity for discrimination are amplified.

As a first step we standardize all selected features in order to give them a uniform relevance. Then, we calculate $\rho_K = \sqrt{J_K}$ for each feature k . Next, we normalize ρ_K as shown in (4).

$$\varrho_k = \frac{\rho_k}{\sum_{i=1}^k \rho_i} \quad (4)$$

Finally, each ϱ_k is used to weigh all the standardized observations for the feature k .

4 Experiments Setup

In this work, the weighted K-NN and MLP algorithms were used for classification. Several experiments were conducted to compare the impact of different image preprocessing and feature enhancement algorithms on classification accuracy. The algorithms used in the training and testing stages included LFA for image normalization and preprocessing, Eigenfaces for dimensionality reduction, FR for selection of the best features, and W for weighting the features based on their discriminative capacity between classes. These two algorithms together aim to improve the discriminative ability of the features across classes. A total of five experiments were conducted for each classifier, which are described in Fig. 8.

A total of 1250 COVID-19 images and 1250 normal images, all of size 256×256 pixels, were used. The region of interest was extracted from these images using the LFA algorithm, forming a bank of normalized images. The images were divided into 2000 training images, with 1000 from each class. For the testing phase, 500 images were selected, with 250 from each class. In the experiments using Eigenfaces-based features, 600 features were used.

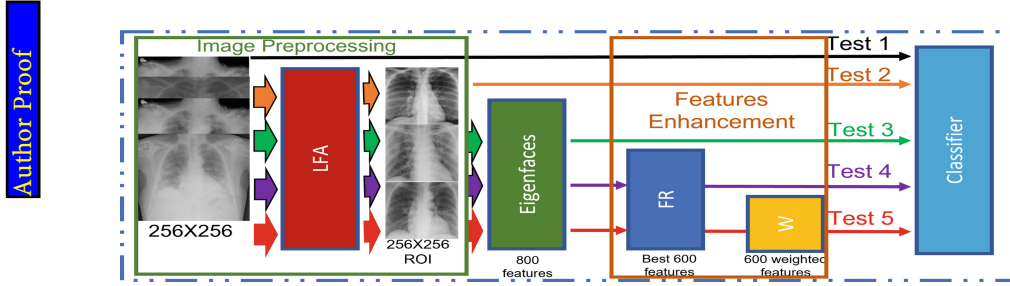


Fig. 8. Graphical representation of the different experiments conducted in image preprocessing. Each arrow represents a sequence of algorithms that may include image preprocessing or feature enhancement. A classification accuracy value is calculated for each arrow.

For the MLP topology, 4 hidden layers with 120 neurons each and a single neuron in the output layer were utilized. The training was conducted for 100 epochs.

5 Experimental Results

Different values were tested for the parameter K in the weighted K -NN, and it was found that the optimal value is 11. On the other hand, experiments were conducted with various topologies and number of epochs in the MLP, but no significant improvements in classification accuracy were observed. The classification accuracy results for all experiments of each classifier are shown in Table 2.

Table 2. Results of the Weighted K -NN and the MLP for the experiments using different preprocessing methods.

Classifier	E1	E2	E3	E4	E5
Weighted K -NN	82.4%	87.8%	88%	91.2%	95.2%
MLP	85%	90.6%	90.8%	93%	97%

Additional tests were conducted in Experiment 5, varying the number of features for both classifiers. However, it was found that 600 is the optimal number of features for both classifiers. Furthermore, Experiment 5 underwent cross-validation to demonstrate the consistency of the proposed set of algorithms in this work. Table 3 displays the results of the 5 tests, along with the average and standard deviation for each classifier.

Table 3. Results of Weighted K-NN and MLP for cross-validation.

Classifier	Test 1	Test 2	Test 3	Test 4	Test 5	Mean	Std
Weighted K-NN	95%	94.8%	95%	94.6%	95.2%	94.92%	0.0022
MLP	97%	96.8%	96.4%	97%	96.8%	96.8%	0.0024

6 Discussion of Results

For both classifiers, the following statements can be made regarding the experiments conducted in image preprocessing:

1. Experiment one, where images have no preprocessing, generally exhibits the worst results.
2. Experiment two demonstrates that image normalization improves results compared to experiment one.
3. In experiment three, where an image representation is projected onto the Eigenfaces space, no notable improvement is observed.
4. Experiment four highlights the importance of feature selection that effectively separates classes using FR, resulting in improved accuracy.
5. Experiment five showcases the effectiveness of our algorithm sequence, which includes image normalization, feature selection, and weighting, yielding the best results.

Additionally, the results demonstrate consistency with minimal variability during cross-validation. Finally, the MLP achieved accuracy results that can compete with other state-of-the-art algorithms for classifying chest X-ray images.

7 Conclusions and Future Work

In this study, we proposed a technique for automatic detection and normalization of the Region of Interest (ROI) in chest radiographs, along with a feature selection method based on Fisher's criterion (FR) using PCA for automatic COVID-19 detection. With the proposed method, a reduced number of highly discriminative features are obtained. The results demonstrate that by utilizing both ROI alignment and feature selection processes, a significant increase in classification accuracy is achieved when using traditional classifiers such as weighted K-NN and MLP. The reported results are reliable as cross-validation techniques were employed to obtain them.

The contributions of this work include a ROI normalization method for lung images and a technique for selecting highly discriminative features using FR. Our approach achieves accuracy values that compete with other state-of-the-art works employing CNN-based techniques.

For future work, the ROI normalization technique can be applied to other databases and for the detection of other lung diseases. Additionally, the feature selection and weighting approaches can be tested to enhance the accuracy of other classification algorithms.

References

1. Alzahrani, S.A., Al-Salamah, M.A., Al-Madani, W.H., Elbarbary, M.A.: Systematic review and meta-analysis for the use of ultrasound versus radiology in diagnosing of pneumonia. *Crit. Ultrasound J.* **9**(1), 6 (2017)
2. Amatya, Y., Rupp, J., Russell, F.M., Saunders, J., Bales, B., House, D.R.: Diagnostic use of lung ultrasound compared to chest radiograph for suspected pneumonia in a resource-limited setting. *Int. J. Emerg. Med.* **11**(1), 8 (2018). [clinicalTrials.gov/NCT02949141](https://clinicaltrials.gov/NCT02949141)
3. Changawala, V., Sharma, K., Paunwala, M.: Averting from convolutional neural networks for chest X-ray image classification. In: 2021 IEEE International Conference on Signal Processing, Information, Communication and Systems (SPIC-SCON), pp. 14–17 (2021)
4. Chowdhury, M.E.H., et al.: Can AI help in screening viral and COVID-19 pneumonia? *IEEE Access* **8**, 132665–132676 (2020)
5. Cleophas, T., Zwinderman, A.: *Machine Learning in Medicine: Part Two, Machine Learning in Medicine*. Springer, Cham (2013). <https://doi.org/10.1007/978-94-007-6886-4>
6. Daszak, P., Keusch, G.T., Phelan, A.L., Johnson, C.K., Osterholm, M.T.: Infectious disease threats: a rebound to resilience. *Health Aff. (Millwood)* **40**(2), 204–211 (2021)
7. Do, T.N., Le, V.T., Doan, T.H.: SVM on top of deep networks for COVID-19 detection from chest X-ray images. *J. Inf. Commun. Convergence Eng.* **20**, 219–225 (2022)
8. El-Kenawy, E.S., et al.: Advanced meta-heuristics, convolutional neural networks, and feature selectors for efficient COVID-19 X-ray chest image classification. *IEEE Access* **9**, 36019–36037 (2021)
9. Ertel, W., Black, N.: *Introduction to Artificial Intelligence. Undergraduate Topics in Computer Science*. Springer, Cham (2018). <https://doi.org/10.1007/978-3-319-58487-4>
10. Gadermayr, M., Cooper, S.S., Klinkhammer, B., Boor, P., Merhof, D.: A quantitative assessment of image normalization for classifying histopathological tissue of the kidney. In: Roth, V., Vetter, T. (eds.) *GCPR 2017. LNCS*, vol. 10496, pp. 3–13. Springer, Cham (2017). https://doi.org/10.1007/978-3-319-66709-6_1
11. Gazda, M., Plavka, J., Gazda, J., Drotar, P.: Self-supervised deep convolutional neural network for chest X-ray classification. *IEEE Access* **9**, 151972–151982 (2021)
12. Gonzalez, R., Woods, R.: *Digital Image Processing, Global Edition*. Pearson Education, New York (2018)
13. Hamza, A., et al.: COVID-19 classification using chest X-ray images based on fusion-assisted deep Bayesian optimization and Grad-CAM visualization. *Front. Public Health* **10**, 1046296 (2022)
14. Ibis, E.: *Sistema de aprendizaje automático para la detección de neumonía*. Master's thesis, Benemérita Universidad Autónoma de Puebla, Puebla, México (2022)
15. Islam, N., et al.: Thoracic imaging tests for the diagnosis of COVID-19. *Cochrane Database Syst. Rev.* **3**(3), CD013639 (2021)
16. Jolliffe, I.: *Principal Component Analysis. Springer Series in Statistics*. Springer, New York (2002). <https://doi.org/10.1007/b98835>
17. Khan, A., Khan, S., Saif, M., Batool, A., Sohail, A., Khan, M.: A survey of deep learning techniques for the analysis of COVID-19 and their usability for detecting Omicron. *J. Exp. Theor. Artif. Intell.* (2022)

18. Kirby, M., Sirovich, L.: Application of the Karhunen-Loeve procedure for the characterization of human faces. *IEEE Trans. Pattern Anal. Mach. Intell.* **12**(1), 103–108 (1990)
19. Kociolek, M., Strzelecki, M., Obuchowicz, R.: Does image normalization and intensity resolution impact texture classification? *Comput. Med. Imaging Graph.* **81**, 101716 (2020)
20. Liu, W., Zheng, Y., Zhou, X., Chen, Q.: Axis orbit recognition of the hydropower unit based on feature combination and feature selection. *Sensors* **23**(6), 2895 (2023)
21. Lv, C., et al.: A classification feature optimization method for remote sensing imagery based on Fisher score and MRMR. *Appl. Sci.* **12**, 8845 (2022)
22. Mikołajczyk-Bareła, A., Grochowski, M.: Data augmentation for improving deep learning in image classification problem, pp. 117–122 (2018)
23. Moberg, A., Taléus, U., Garvin, P., Fransson, S.G., Falk, M.: Community-acquired pneumonia in primary care: clinical assessment and the usability of chest radiography. *Scand. J. Prim. Health Care* **34**, 1–7 (2016)
24. Moeslund, T.B.: Introduction to Video and Image Processing: Building Real Systems and Applications. Undergraduate Topics in Computer Science. Springer, London (2012). <https://doi.org/10.1007/978-1-4471-2503-7>
25. Muljo, H.H., Pardamean, B., Purwandari, K., Cenggoro, T.W.: Improving lung disease detection by joint learning with COVID-19 radiography database. *Commun. Math. Biol. Neurosci.* **2022**(1), 1–24 (2022)
26. Mustafa Ghaderzadeh, M.A., Asadi, F.: X-ray equipped with artificial intelligence: changing the COVID-19 diagnostic paradigm during the pandemic. *Biomed. Res. Int.* **2021**, 9942873 (2021)
27. Niederman, M.S.: Community-acquired Pneumonia. *Ann. Internal Med.* **163**(7), ITC1–ITC16 (2015)
28. Nillmani, et al.: Segmentation-based classification deep learning model embedded with explainable AI for COVID-19 detection in chest X-ray scans. *Diagnostics* **12**(9), 2132 (2022)
29. Park, S.H., Lee, S.G.: A method of feature extraction on motor imagery EEG using FLD and PCA based on Sub-Band CSP. *J. KIISE* **42**, 1535–1543 (2015)
30. Qin, C., Yao, D., Shi, Y., Song, Z.: Computer-aided detection in chest radiography based on artificial intelligence: a survey. *Biomed. Eng. Online* **17**(1), 113 (2018)
31. Rahman, T., et al.: Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images. *Comput. Biol. Med.* **132**, 104319 (2021)
32. Ridzuan, M., Bawazir, A.A., Navarette, I.G., Almakky, I., Yaqub, M.: Self-supervision and multi-task learning: challenges in fine-grained COVID-19 multi-class classification from chest X-rays (2022)
33. Salvatore, C., et al.: Artificial intelligence applied to chest X-ray for differential diagnosis of COVID-19 Pneumonia. *Diagnostics (Basel)* **11**(3), 530 (2021)
34. Shorten, C., Khoshgoftaar, T.M.: A survey on image data augmentation for deep learning. *J. Big Data* **6**(1), 60 (2019)
35. Silva, T.S.: An illustrative introduction to Fisher’s linear discriminant (2019). <https://sthalles.github.io>
36. Szeliski, R.: Computer Vision: Algorithms and Applications, 1st edn. Springer, Heidelberg (2010). <https://doi.org/10.1007/978-3-030-34372-9>
37. Talaat, A., Yousri, D., Ewees, A., Al-qaness, M.A.A., Damaševičius, R., Elsayed Abd Elaziz, M.: COVID-19 image classification using deep features and fractional-order marine predators algorithm. *Sci. Rep.* **10**, 15364 (2020)

38. Ticinesi, A., et al.: Lung ultrasound and chest X-ray for detecting pneumonia in an acute geriatric ward. *Medicine (Baltimore)* **95**(27), e4153 (2016)
39. Turk, M., Pentland, A.: Eigenfaces for recognition. *J. Cogn. Neurosci.* **3**(1), 71–86 (1991)

Author Queries

Chapter 17

Query Refs.	Details Required	Author's response
AQ1	This is to inform you that corresponding author has been identified as per the information available in the Copyright form.	
AQ2	Please check and confirm if the authors given and family names have been correctly identified.	
AQ3	As per the Table of Contents, we have expanded the author names in the author group. Please check and confirm if this is ok.	
AQ4	Please be aware that your name and affiliation and if applicable those of your co-author(s) will be published as presented in this proof. If you want to make any changes, please correct the details now. Please note that after publication corrections won't be possible. Due to data protection we standardly publish professional email addresses, but not private ones, even if they have been provided in the manuscript and are visible in this proof. If you or your co-author(s) have a different preference regarding the publication of your mail address(s) please indicate this clearly. If no changes are required for your name(s) and affiliation(s) and if you agree with the handling of email addresses, please respond with "Ok".	
AQ5	Kindly note that citations of Parts 1 to 7 have been changed to citations of Sects. 1 to 7. Please check and confirm.	
AQ6	Please check and confirm if the inserted citation of Fig. 7 is correct. If not, please suggest an alternate citation.	



Estudio Comparativo entre la Normalización y la Segmentación Semántica de la Región Pulmonar en Imágenes Radiográficas de Tórax para el Reconocimiento Automático de COVID-19

Comparative Study between Normalization and Semantic Segmentation of the Lung Region in Chest Radiographic Images for Automatic COVID-19 Recognition.

Angel Ernesto Picazo-Castillo¹, Salvador E. Ayala-Raggi¹, Leopoldo Altamirano-Robles², Aldrin Barreto-Flores¹, José Francisco Portillo-Robledo¹

¹Benemérita Universidad Autónoma de Puebla, Puebla, México.

²Instituto Nacional de Astrofísica, Óptica y Electrónica, Puebla, México.
a.picazo.2505@gmail.com, saraggi@gmail.com, robles@inaoep.mx.

Abstract

This paper presents an automatic method for COVID-19 recognition based on the localization and normalization of the position, rotation, and scale of the region of interest (the lungs) in chest X-ray images. To achieve this, we use Principal Component Analysis (PCA) and weighted K-NN regression. Our technique involves estimating the positions of the corners of the region of interest through interpolation and mapping the image within that region to a standardized fixed-size template. The main objective is to normalize all training images in terms of position, angular orientation, scale, and contrast. In addition, we employ semantic segmentation of the lungs by applying masks generated in a previous work to compare different representations of the same X-ray and determine which one is optimal for classification. For image classification, we use the convolutional neural networks MobileNetV2, ResNet-50, Resnet-18, Compact, and AlexNet, along with a classifier proposed by the authors. The proposed classifier consists of the "Eigenfaces" method to reduce the number of features from the X-rays, Fisher's discriminant criterion to select and weigh the most relevant features, and a Multi-Layer Perceptron (MLP) for classification. The results of our experiments demonstrate that image normalization provides better results than lung segmentation. All classifiers used experienced an increase in accuracy, with MobileNetV2 and our proposed classifier standing out, achieving an accuracy of 97.6% and 97%, respectively. Our normalization method, along with the proposed classifier, uses simple machine learning algorithms and achieves similar or superior results compared to some convolutional neural network-based algorithms.

Resumen

En este artículo se presenta un método automático para el reconocimiento de COVID-19 basado en la localización y normalización de la posición, rotación y escala de la región de interés (los pulmones) en radiografías de tórax. Para lograr esto, utilizamos el Análisis de Componentes Principales (PCA) y

Estudio comparativo entre la Normalización y la Segmentación

la regresión ponderada K-NN. Nuestra técnica consiste en estimar las posiciones de las esquinas de la región de interés mediante interpolación y mapear la imagen dentro de esa región a una plantilla de tamaño fijo estandarizado. El objetivo principal es normalizar todas las imágenes de entrenamiento en términos de posición, orientación angular, escala y contraste. Además, utilizamos la segmentación semántica de los pulmones aplicando las máscaras generadas en un trabajo previo para comparar diferentes representaciones de la misma radiografía y determinar cuál es la óptima para la clasificación. Para realizar la clasificación de las imágenes, utilizamos las redes neuronales convolucionales MobileNetV2, ResNet-50, Resnet-18, Compact y AlexNet, junto con un clasificador propuesto por los autores. El clasificador propuesto consta del método de "Eigenfaces" para reducir la cantidad de características de las radiografías, el criterio discriminante de Fisher para seleccionar y ponderar las características más relevantes y un MLP para la clasificación. Los resultados de nuestros experimentos demuestran que la normalización de imágenes proporciona mejores resultados que la segmentación de pulmones. Todos los clasificadores utilizados experimentaron un aumento en la precisión, destacando la MobileNetV2 y nuestro clasificador propuesto, con una precisión del 97.6% y 97%, respectivamente. Nuestro método de normalización, junto con el clasificador propuesto, utilizan algoritmos simples de aprendizaje automático y logra resultados similares o superiores a algunos de los algoritmos basados en redes convolucionales.

Keywords and phrases: COVID-19, Redes Neuronales Convolucionales, Segmentación de pulmones, Perceptrón multicapa, Clasificación de imágenes.

2020 Mathematics Subject Classification: 68N01

1 Introducción

El COVID-19 es una enfermedad respiratoria causada por el virus SARS-CoV-2. Se transmite principalmente a través de gotas respiratorias y puede provocar síntomas como fiebre, tos y dificultad para respirar. Además de las pruebas de laboratorio, las radiografías de tórax se utilizan como herramienta de detección para evaluar posibles signos de infección pulmonar causada por el virus. Estas imágenes pueden mostrar patrones característicos, como opacidades o infiltrados, que ayudan a los médicos en el diagnóstico y seguimiento de la enfermedad, como se muestra en [1]. Varios estudios han demostrado la eficacia de las radiografías de tórax en la detección del COVID-19, como se describe en [2-4]. Sin embargo, la problemática actual radica en la falta de uniformidad en la alineación y el brillo de la región de interés (los pulmones) en las radiografías etiquetadas disponibles en bancos de información, como se puede observar en [5,6]. La construcción de estos bancos ha sido un esfuerzo conjunto de instituciones y médicos expertos en el campo, tal como se menciona en los trabajos [7-9]. Algunas de estas radiografías presentan información no deseada o irrelevante para la clasificación, lo que puede afectar negativamente las métricas de precisión de los algoritmos de aprendizaje automático, como se comenta en [6,21].

En este estudio comparativo, se realiza una comparación entre dos métodos de preprocesamiento de imágenes, los cuales se aplican tanto en las imágenes de entrenamiento como en las de prueba para su posterior clasificación. El primer método implica la aplicación de la segmentación semántica en la región de interés con el fin de extraer imágenes que contengan exclusivamente los pulmones,

como se describe en [6]. El segundo método es una propuesta que busca alinear la región de interés de manera que las estructuras anatómicas dentro del pulmón coincidan en posición en todas las imágenes. Cabe resaltar que este proceso de normalización de imágenes se realiza sin el uso de Redes Neuronales Convolucionales (CNNs). En el proceso de clasificación de imágenes, se emplean diversas redes neuronales convolucionales, como MobileNetV2, ResNet-50, ResNet-18, Compact y AlexNet, disponibles en el programa MVTEC Deep Learning Tool. Además, se introduce un clasificador propuesto que se compone inicialmente de la reducción de dimensiones de las imágenes radiográficas mediante el método de las "Eigenfaces" (una técnica basada en el Análisis de Componentes Principales). A continuación, se lleva a cabo la selección y ponderación de las características más distintivas de las clases utilizando el criterio discriminante de Fisher. Finalmente, se emplea un algoritmo MLP para la clasificación. En consecuencia, se propone la aplicación de dos procesos secuenciales. El primero corresponde a un preprocesamiento de imágenes que engloba la detección y normalización de la región pulmonar. En otras palabras, se busca que las imágenes dentro de la región pulmonar tengan la misma alineación, ubicación y escala en la medida de lo posible, además de mejorar el contraste. El segundo proceso tiene como objetivo optimizar las características mediante la implementación del método de las "Eigenfaces" (PCA) en las regiones alineadas. Esto conduce a la obtención de un conjunto reducido de características estadísticamente independientes. Finalmente, basándonos en el criterio discriminante de Fisher descrito en [23], se sugiere llevar a cabo una selección de las características que logren una mejor discriminación entre las clases. Mediante este conjunto de características optimizadas y la utilización de un clasificador tradicional, como el MLP, se busca alcanzar valores de precisión en la clasificación que puedan ser comparables con los obtenidos a través de las CNNs.

Este trabajo está organizado en seis secciones. En la sección 2, se ofrece un análisis exhaustivo del estado del arte relacionado con el tema central de esta investigación. La sección 3 presenta tanto la teoría como los resultados de nuestro algoritmo propuesto, denominado "Algoritmo Localizador de Pulmones" (ALP), el cual despliega un papel fundamental en el proceso de normalización. En la sección 4, se detalla el conjunto de imágenes empleado en este estudio, incluyendo su composición y características. Asimismo, se definen los experimentos que se llevarán a cabo, estableciendo el terreno para la presentación de resultados y discusiones en la sección 5. Por último, la sección 6 engloba las conclusiones obtenidas a través de este estudio y sugiere posibles líneas de trabajo futuro.

2 Estado del Arte

En la actualidad, se han desarrollado diversas metodologías para la clasificación de radiografías de tórax, como ha sido evidenciado en estudios previos [5,6,10-13]. Estas metodologías hacen uso tanto de algoritmos de aprendizaje profundo como de clasificadores tradicionales de aprendizaje de máquina [14,15], y han reportado niveles elevados de precisión en la clasificación, alcanzando entre un 96% y un 99%. Sin embargo, las arquitecturas empleadas en estos algoritmos todavía enfrentan desafíos para lograr una clasificación confiable del COVID-19, como se comenta en [16], ya que su precisión tiende a disminuir al aplicarse a otros conjuntos de imágenes. Esto plantea la posibilidad de explorar nuevas propuestas para la clasificación de radiografías que no se basen en redes neuronales convolucionales (CNN), como se abordó en un estudio anterior [17]. En dicho estudio, se empleó un Perceptrón Multicapa (MLP) y una arquitectura fundamentada en la involución de

Estudio comparativo entre la Normalización y la Segmentación

imágenes. Esta última propone kernels similares a los de las CNNs, pero comparte sus pesos de manera dinámica en todas las dimensiones, reduciendo así la cantidad de multiplicaciones necesarias para los cálculos. Esta propuesta logró una precisión máxima de clasificación del 94.83%.

Los trabajos de reconocimiento de COVID-19 en radiografías de tórax que no se basan en CNNs comparten similitudes en su metodología. En primer lugar, hacen uso de técnicas de preprocesamiento de imágenes, como se observa en [18,19,21,22], donde se emplean diversos tipos de filtros en las imágenes para reducir el ruido. Además, en [18,19] se utilizan técnicas de mejora de contraste. Posteriormente, aplican técnicas para la reducción y selección de características de las imágenes que se emplean en la etapa de preprocesamiento. Finalmente, proceden a la clasificación de las imágenes. La tabla 1 proporciona una comparación de los diferentes trabajos relacionados junto con sus respectivas técnicas de preprocesamiento de imágenes, técnicas de extracción de características, algoritmo clasificador utilizado y porcentaje de precisión en la clasificación [18-22]. El algoritmo Support Vector Machine (SVM) demuestra tener los mejores resultados, y en [19,21] obtienen resultados equiparables al uso de CNNs.

Es importante resaltar que los resultados obtenidos en este estudio no tienen la intención de reemplazar a las CNNs en la clasificación de imágenes, sino más bien de presentar una alternativa como se ha hecho en [19,21], demostrando que la alineación de imágenes y una selección adecuada de características pueden ofrecer resultados comparables a los algoritmos más comunes en el estado del arte, sin la necesidad de entrenar millones de parámetros.

Tabla 1. Trabajos que realizan detección de COVID-19 en radiografías de tórax sin usar CNNs.

Autores	Preprocesamiento de imágenes	Extracción de características	Clasificador	Precisión
Bazhdar et al., (2021)	Filtro Gaussiano, AHE	Patrón Binario Local	SVM	94.6%
Prabhu et al.,(2022)	Filtro de Mediana, HE	Histograma de Gradientes Orientados	SVM	97%
Samsir et al.,(2021)	Algoritmo Genético	Fusión de características	Naives Bayes	92.6%
Akram et al., (2021)	Filtro de Mediana	PCA	MWOA-SSA	97%
Kadry et al.,(2020)	Filtro de Umbralización	Transformada Discreta de Ondas	SVM	89%

3 Funcionamiento del Algoritmo Localizador de Pulmones (ALP)

El objetivo de este algoritmo es localizar los pulmones en las radiografías, y consta de una etapa de entrenamiento y prueba, tal como se ilustra en la Figura 1. Durante la fase de entrenamiento, se seleccionaron al azar 400 imágenes de las clases Neumonía, COVID-19 y Normal del conjunto de datos. A todas las imágenes se les aplicó la ecualización de histogramas (HE), y las regiones de interés se etiquetaron manualmente mediante la colocación de 4 puntos de referencia provisionales, los cuales son fácilmente localizables por un usuario humano. Se acordó que dos de estos puntos estarían ubicados en el centro de las vértebras cervicales, justo en el límite superior de los pulmones. El tercer punto se situó en la columna vertebral, pero por debajo de la región pulmonar. Los últimos dos puntos provisionales requerían que el usuario los colocara a lo largo de una línea recta imaginaria perpendicular a la columna vertebral, cortándola justo en el medio de los dos puntos de

referencia anteriores. Estos dos últimos puntos se posicionaron en los lados izquierdo y derecho de la región pulmonar. Finalmente, utilizando estas 4 posiciones provisionales, se calcularon 4 puntos de referencia definitivos y permanentes en las esquinas de la región pulmonar rectangular.

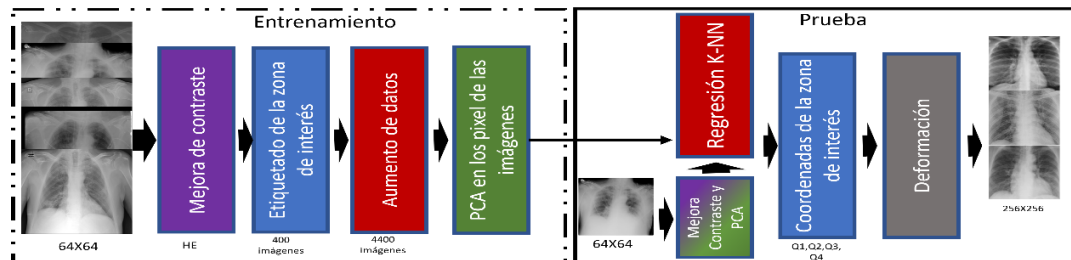


Figura 1. Descripción del Algoritmo Localizador de Pulmones. En la entrada de la etapa de prueba se encuentra un nuevo ejemplo y a la salida se tiene la ROI ya extraída de manera automática.

Por otro lado, se procedió a generar diez nuevas imágenes para cada imagen etiquetada, aplicando rotaciones y desplazamientos aleatorios. Esta técnica de aumento de datos permitió ampliar el conjunto de datos, resultando en un conjunto más robusto y diverso. El rango de rotación utilizado fue de -10° a 10° , siguiendo la sugerencia en [6], mientras que para la traslación se consideró un rango de -5 a 5 píxeles. Estos rangos garantizaron que las landmarks mantuvieran una distribución normalizada. Posteriormente, se aplicó una técnica de reducción de dimensionalidad conocida como "Eigenfaces", basada en el Análisis de Componentes Principales (PCA), como se propuso en [24,25]. Esto se realizó en el conjunto de las 4400 imágenes generadas, lo que permitió crear un subespacio lineal que captura las variaciones más significativas en los datos. En la fase de prueba, después de aplicar una mejora de contraste mediante la ecualización del histograma (HE), cada nueva imagen se proyectó en el subespacio lineal "Eigenfaces". Esto transformó la imagen en un vector compacto de dimensiones reducidas. Luego, utilizando la distancia euclidiana, se comparó este vector con cada uno de los 4400 ejemplos del conjunto de datos aumentado, encontrando los k vecinos más cercanos a través del algoritmo k -NN Ponderado. Los puntos de referencia asociados a estas k imágenes más similares del conjunto de datos aumentado se utilizaron para predecir los 4 puntos de referencia de la imagen de prueba mediante interpolación. Estos puntos predichos representan las coordenadas de las esquinas de la Región de Interés (ROI) del pulmón. Estas coordenadas permiten deformar la región interior de la imagen hacia una plantilla estándar de tamaño fijo de 256×256 píxeles, lo que facilita la extracción consistente de la ROI. Para ejemplificar este proceso, la figura 2 muestra casos de deformación y extracción exitosa de la ROI.




Figura 2. Imágenes de ejemplo con sus regiones de interés ya extraídas en imágenes normalizadas. Las coordenadas rojas son obtenidas por regresión y las azules se usan en la extracción de la ROI.

3.1 Reducción de dimensiones.

Después de utilizar el ALP en todas las radiografías del conjunto de datos para extraer todas las regiones de interés, estas nuevas imágenes se someten a un preprocesamiento adicional antes de ser procesadas por un algoritmo clasificador. Para nuestro trabajo, proponemos el uso de las Eigenfaces. como método de reducción de características. Además, incorporamos el análisis estadístico de estas características utilizando el discriminante lineal de Fisher [23]. Estos dos métodos en conjunto aseguran la obtención de un número reducido de características que mejor discriminan las clases para su posterior clasificación. El método de las Eigenfaces fue inicialmente desarrollado por Turk y Pentland en [24] y por Sirovich y Kirby en [25]. Este método se basa en el análisis de componentes principales (PCA) y su objetivo es reducir la dimensionalidad de las imágenes en la base de datos. Debido a que cada píxel se convierte en una dimensión o variable a analizar, el procesamiento de imágenes de alta resolución como las de 256x256 puede llevar mucho tiempo. Cada Eigenface es una imagen que muestra una estructura de rasgos o patrones comunes en el conjunto de imágenes utilizado. Estas Eigenfaces se ordenan según la varianza de las imágenes de entrada y se pueden utilizar para reconstruir cualquier imagen como una combinación lineal de ellas, lo que permite representarla en un espacio de menor dimensión. En la figura 3 se muestra la ecuación de las Eigenfaces y la matriz Q de Eigenfaces. Sin embargo, es importante que las imágenes de entrada tengan condiciones de iluminación y ángulo similares. Por esta razón, el ALP se utiliza previamente como un método para normalizar las radiografías.

$$\rightarrow \bar{X} = QX + \Psi \leftarrow$$

Figura 3. Imagen de salida (Izquierda) como la combinación lineal de la matriz de Eigenfaces Q (medio) y la imagen de entrada más la cara media (derecha).

3.2 Selección y ponderación de características mediante el criterio discriminante de Fisher.

El criterio discriminante de Fisher, también conocido como razón de Fisher (FR por sus siglas en inglés), se ha utilizado en el Análisis Discriminante Lineal para encontrar una proyección lineal de características que maximice la separación entre clases. Normalmente, en problemas de dos clases, solo una característica importante sobrevive a este proceso. Sin embargo, dado que las características obtenidas mediante PCA son en cierta medida independientes, podemos utilizar, de manera ingenua, la razón de Fisher como una medida de separación entre clases para cada característica. Este proceso se realiza evaluando cada característica de forma individual y asegurándose de que las medias de las observaciones en cada clase estén lo más separadas posible, mientras que las varianzas dentro de cada clase sean lo más pequeñas posible. Utilizando este análisis, es posible seleccionar un número mayor que 2 de esas características obtenidas mediante el método de Eigenfaces que mejor discriminan las clases en el conjunto de datos. La fórmula de la razón de Fisher se encuentra en la ecuación 1 y el valor obtenido se denota como J. Proponemos utilizar el valor de la razón de Fisher (FR) como un peso para cada característica, de manera que

aquellas características que posean una mayor capacidad de discriminación sean amplificadas. Como primer paso, estandarizamos todas las características seleccionadas para darles una relevancia uniforme. Luego, calculamos $\rho_k = \sqrt{J_k}$ para cada característica k. A continuación, normalizamos ρ_k como se muestra en la ecuación 2. Finalmente, cada q_k se utiliza para ponderar todas las observaciones estandarizadas correspondientes a la característica k.

$$J_i = \frac{(\mu_{ic0} - \mu_{ic1})^2}{\sigma_{ic1}^2 + \sigma_{ic2}^2} \quad (1)$$

$$q_k = \frac{\rho_k}{\sum_{i=1}^k \rho_i} \quad (2)$$

4 Conjunto de imágenes y preparación para los experimentos.

El conjunto de imágenes utilizado en este estudio fue "COVID-19 Radiography Database", disponible en Kaggle [5,6]. El conjunto de datos contiene un total de 6012 imágenes etiquetadas como opacidad pulmonar (otras enfermedades pulmonares), 1345 como neumonía viral, 10,192 como normales y 3616 como COVID-19. También, el conjunto incluye máscaras para segmentar las regiones de interés (ROI) de las radiografías, generadas en [6]. Se usaron 1250 radiografías de COVID-19 y otras 1250 radiografías normales seleccionadas al azar del conjunto de imágenes, todas con una dimensión de 256x256 píxeles. Estas imágenes se dividieron en un conjunto de entrenamiento de 2000 imágenes, con 1000 en cada categoría. Para la fase de prueba, se eligieron 500 imágenes, 250 por cada clase, para asegurar un conjunto de pruebas equilibrado. La Figura 4 ilustra los procedimientos realizados de manera simultánea en relación con las radiografías para llevar a cabo los experimentos. En el primer experimento, se aplicaron máscaras a las radiografías para obtener imágenes que contuvieran exclusivamente la Región de Interés (ROI). En el segundo experimento, se empleó el Algoritmo Localizador de Pulmones (ALP) de manera automática para realizar la normalización de las radiografías. También se presentan ejemplos visuales en esta figura de las radiografías originales, las imágenes resultantes tras la aplicación del ALP y las imágenes obtenidas a partir de la segmentación de la ROI.

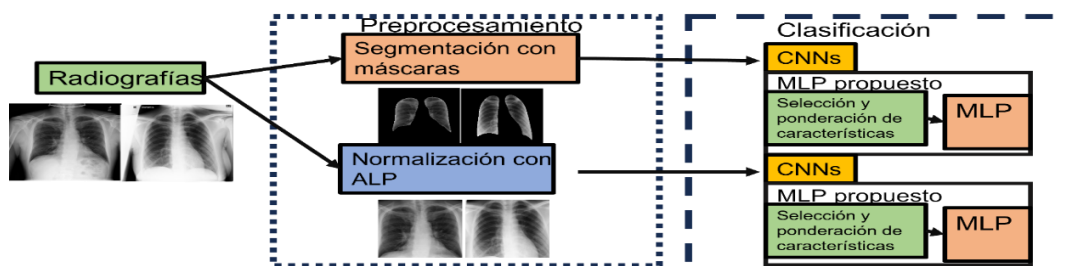


Figura 4. Secuencia de experimentos. En el primero, se lleva a cabo la segmentación de la ROI en las radiografías. En el segundo, se procede a la normalización de las radiografías mediante el uso del ALP. En ambos experimentos, se realiza la clasificación utilizando CNNs y el clasificador propuesto.

Se utilizaron las redes convolucionales MobileNetV2, ResNet-50, ResNet-18, Compact y AlexNet, además de nuestro MLP propuesto, para llevar a cabo la clasificación. Todas las redes convolucionales se implementaron utilizando el software MVTEC Deep Learning Tool 23.04. El proceso de entrenamiento se realizó durante 100 épocas, utilizando un tamaño de lote de 32 y una

Estudio comparativo entre la Normalización y la Segmentación

tasa de aprendizaje de 0.001. En el caso del clasificador propuesto, se emplearon las Eigenfaces para reducir la dimensionalidad de las características y el criterio discriminante de Fisher (FR) para seleccionar y ponderar las características más relevantes en función de su capacidad de discriminación entre clases. Ambos algoritmos se utilizaron en conjunto para mejorar la capacidad de discriminación de las características antes de entrenar el MLP. La topología del MLP consistió en 600 características para la capa de entrada, seguida de 4 capas ocultas, cada una con 120 neuronas, y una única neurona en la capa de salida. El proceso de entrenamiento se llevó a cabo durante 100 épocas.

5 Resultados experimentales y discusión sobre los resultados.

A continuación, en la tabla 2, se muestran los resultados de precisión en la clasificación de todos los algoritmos después de aplicar validación cruzada para ambos experimentos. También se incluye en la segunda columna el resultado de no utilizar ningún preprocesamiento de imágenes antes de la clasificación.

Tabla 2. Resultados de precisión de las CNNs y el clasificador propuesto para los experimentos.

Clasificador	Radiografías Originales	Normalización con ALP	Segmentación con máscaras
MobileNetV2	89%	97.6%	95.6%
ResNet-50	88.4%	96%	91.5%
ResNet-18	88.8%	96.4%	95.6%
Compact	87%	90.8%	85.9%
AlexNet	85.2%	90%	87.5%
clasificador propuesto	88%	97%	90%

En primer lugar, se observa que el uso de las imágenes originales no es recomendable, ya que se obtienen los peores resultados de clasificación. La Segmentación con máscaras muestra una mayor variabilidad en términos de forma y tamaño de la ROI, y se puede observar que la ResNet-18 y la MobileNet V2 obtuvieron los mejores resultados al usar este método de preprocesamiento. El clasificador propuesto se ve afectado debido a la variabilidad de esta base de datos, lo cual afecta el PCA utilizado. En cuanto a la Normalización con ALP, se puede observar que nuestro clasificador propuesto y la MobileNetV2 obtuvieron los mejores desempeños. Además, todos los clasificadores experimentaron un incremento en su precisión. Esto se debe a que la variabilidad al usar la Normalización con ALP es menor. Nuestro clasificador propuesto alcanza su mejor métrica de precisión al utilizar esta base de datos, ya que es más compatible con la reducción mediante PCA y la selección y ponderación de características mediante el FR. En general, se puede afirmar que, en nuestras pruebas, la normalización de imágenes demuestra ser una mejor representación para la clasificación de radiografías.

6 Conclusiones y trabajo futuro

En este trabajo, se propuso una técnica de detección y normalización automática de la ROI en radiografías de tórax llamado ALP, además proponemos un clasificador para la detección automática de COVID-19 que utiliza la selección y ponderación de características basado en el criterio discriminante de Fisher en las características obtenidas las "eigenfaces" y un MLP para la

clasificación. Con el método propuesto de preprocesamiento, se obtiene una representación de una radiografía que puede ser clasificada de mejor manera utilizando cualquier algoritmo clasificador basado o no en CNNs. También los resultados muestran que, al utilizar la alineación de la ROI como preprocesamiento de imágenes y la selección de características, se logra un aumento significativo en la precisión de la clasificación cuando se utilizan clasificadores tradicionales como el MLP. Los resultados reportados son confiables, ya que se utilizaron técnicas de validación cruzada para obtenerlos. Las contribuciones de este trabajo incluyen un método de normalización de la ROI en imágenes pulmonares y una técnica de selección de características altamente discriminantes mediante el uso del criterio discriminante de Fisher. Nuestra propuesta logra alcanzar valores de precisión que compiten con otros trabajos del estado del arte que utilizan técnicas basadas en CNNs. Para trabajos futuros, el ALP puede ser utilizado en otros conjuntos de imágenes pulmonares para la detección de otras enfermedades. Además, la selección y ponderación de características pueden ser probadas para mejorar la precisión de clasificación de otros algoritmos de aprendizaje de máquina. El código se encuentra disponible en: <https://github.com/picazo07/LFA>.

Referencias

- [1] Daszak, P., Keusch, G. T., Phelan, A. L., Johnson, C. K., and Osterholm, M. T. (2021). Infectious Disease Threats: A Rebound to Resilience: Commentary reviews the US approach to pandemic preparedness, its impact on the response to COVID-19, and offers policy options to strengthen US pandemic resilience. *Health Affairs*, 40(2),204-211.
- [2] Alzahrani, S. A., Al-Salamah, M. A., Al-Madani, W. H., and Elbarbary, M. A.: Systematic review and meta-analysis for the use of ultrasound versus radiology in diagnosing of pneumonia. *Critical ultrasound journal*, 9(1),6(2017).<https://doi.org/10.1186/s13089-017-0059-y>
- [3] Amatya, Y., Rupp, J., Russell, F. M., Saunders, J., Bales, B., and House, D. R.: Diagnostic use of lung ultrasound compared to chest radiograph for suspected pneumonia in a resource-limited setting. *International journal of emergencymedicine*,11(1),8(2018).<https://doi.org/10.1186/s12245-018-0170-2>
- [4] Moberg, A. B., Taléus, U., Garvin, P., Fransson, S. G., and Falk, M.: Community-acquired pneumonia in primary care: clinical assessment and the usability of chest radiography. *Scandinavian journal of primary health care*,34(1),21–27(2016).<https://doi.org/10.3109/02813432.2015.1132889>
- [5] M.E.H. Chowdhury, T. Rahman, A. Khandakar, R. Mazhar, M.A. Kadir, Z.B. Mahbub, K.R. Islam, M.S. Khan, A. Iqbal, N. Al-Emadi, M.B.I. Reaz, M. T. Islam, “Can AI help in screening Viral and COVID-19 pneumonia?” *IEEE Access*,Vol.8,pp.132665-132676(2020).
- [6] Rahman, T., Khandakar, A., Qiblawey, Y., Tahir, A., Kiranyaz, S., Abul Kashem, S. B., Islam, M. T., Al Maadeed, S., Zughaier, S. M., Khan, M. S., and Chowdhury, M. E. H.: Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images. *Computers in biology and medicine*, 132, 104319 (2021).<https://doi.org/10.1016/j.combiomed.2021.104319>
- [7] Salvatore, C., Interlenghi, M., Monti, C. B., Ippolito, D., Capra, D., Cozzi, A., Schiaffino, S., Polidori, A., Gandola, D., Alì, M., Castiglioni, I., Messa, C., and Sardanelli, F.: Artificial Intelligence Applied to Chest X-ray for Differential Diagnosis of COVID-19 Pneumonia. *Diagnostics (Basel, Switzerland)*,

11(3), 530 (2021). <https://doi.org/10.3390/diagnostics11030530>

[8] Qin, C., Yao, D., Shi, Y. et al.: Computer-aided detection in chest radiography based on artificial intelligence: a survey. *BioMed Eng OnLine* 17, 113 (2018). <https://doi.org/10.1186/s12938-018-0544-y>

[9] Ghaderzadeh, M., Aria, M., and Asadi, F.: X-Ray Equipped with Artificial Intelligence: Changing the COVID-19 Diagnostic Paradigm during the Pandemic. *BioMed research international*, 2021, 9942873 (2021). <https://doi.org/10.1155/2021/9942873>

[10] Khan, A., Khan, D.H., Saif, M., Batool, A., Sohail, A., \& Khan, M.W.: A Survey of Deep Learning Techniques for the Analysis of COVID-19 and their usability for Detecting Omicron. *ArXiv*, abs/2202.06372. (2022).

[11] Hamza, A., Attique Khan, M., Wang, S. H., Alhaisoni, M., Alharbi, M., Hussein, H. S., Alshazly, H., Kim, Y. J., and Cha, J.: COVID-19 classification using chest X-ray images based on fusion-assisted deep Bayesian optimization and Grad-CAM visualization. *Frontiers in public health*, 10, 1046296 (2022). <https://doi.org/10.3389/fpubh.2022.1046296>

[12] Nillmani, Sharma, N., Saba, L., Khanna, N. N., Kalra, M. K., Fouda, M. M., and Suri, J. S.: Segmentation-Based Classification Deep Learning Model Embedded with Explainable AI for COVID-19 Detection in Chest X-ray Scans. *Diagnostics (Basel, Switzerland)*, 12(9), 2132 (2022). <https://doi.org/10.3390/diagnostics12092132>

[13] Gazda, M.,Plavka, J., Gazda, J., and Drotár, P.: Self-Supervised Deep Convolutional Neural Network for Chest X-Ray Classification".in *IEEE Access*,vol.9,pp.151972-151982(2021).doi: 10.1109/ACCESS.2021.3125324.

[14] Thanh-Nghi Do, Van-Thanh Le and Thi-Huong Doan.: SVM on Top of Deep Networks for Covid-19 Detection from Chest X-ray Images. *Journal of Information and Communication Convergence Engineering*, 20(3), 219-225 (2022).

[15] El-Kenawy, El-Sayed M. Towfek, Seyed Mohammad Mirjalili, Abdelhameed Ibrahim, Mohammed F. Alrahmawy, M. El-Said, Rokaia M. Zaki and Marwa Metwally Eid. "Advanced Meta-Heuristics, Convolutional Neural Networks, and Feature Selectors for Efficient COVID-19 X-Ray Chest Image Classification." *IEEE Access* 9 (2021): 36019-36037.

[16] Ridzuan, M., Ali Bawazir, A., Gollini, I., Almakky, I., and Yaqub, M.: Challenges in COVID-19 Chest X-Ray Classification: Problematic Data or Ineffective Approaches?. *ArXiv abs/2201.06052*.(2022).

[17] Changawala, V., Sharma, K. and Paunwala, M.: Averting from Convolutional Neural Networks for Chest X-Ray Image Classification. *IEEE International Conference on Signal Processing, Information, Communication and Systems (SPICSCON)*, Dhaka, Bangladesh,pp. 14-17 (2021). doi: 10.1109/SPICSCON54707.2021.9885316.

[18] Mohammed, B., Al-Mukhtar, F., Yousif, R., & Almashhadani, Y.: Automatic Classification of Covid-19 Chest X-Ray Images Using Local Binary Pattern and Binary Particle Swarm Optimization for Feature Selection. *Cihan University-Erbil Scientific Journal*, 5(2), 46-51. 2021.

A. Picazo et al. / Abstraction & Application **41** (2023)

<https://doi.org/10.24086/cuesj.v5n2y2021.pp46-51>

[19] Samsir, S., Sitorus, J. H. P., Zulkifli, Ritonga, Z., Nasution, F. A., & Watrianthos, R.: Comparison of machine learning algorithms for chest X-ray image COVID-19 classification. *Journal of Physics: Conference Series*, 1933(1),012040.2021.<https://dx.doi.org/10.1088/1742-6596/1933/1/012040>

[20] Akram, T., Attique, M., Gul, S., Shahzad, A., Altaf, M., Naqvi, S. S. R., Damaševičius, R., & Maskeliūnas, R.: A novel framework for rapid diagnosis of COVID-19 on computed tomography scans. *Pattern analysis and applications: PAA*, 24(3), 951–964. 2021. <https://doi.org/10.1007/s10044-020-00950-0>

[21] Budimirovic, N., Prabhu, E., Antonijevic, M., Zivkovic, M., Bacanin, N., Strumberger, I., & Venkatachalam, K.: COVID-19 Severity Prediction Using Enhanced Whale with Salp Swarm Feature Classification. *Computers, Materials & Continua*, 72(1), 1685-1698. 2022. <http://www.techscience.com/cmcc/v72n1/46856>

[22] Kadry, S., Rajinikanth, V., Rho, S., Raja, N. S. M., Rao, V. S., & Thanaraj, K. P.: Development of a Machine-Learning System to Classify Lung CT Scan Images into Normal/COVID-19 Class. 2020. arXiv preprint arXiv:2004.13122.

[23] Silva, T.S.: An illustrative introduction to fisher's linear discriminant. [Online]: <https://sthalles.github.io> (2019), <https://sthalles.github.io/fisher-linear-discriminant/>. [Accessed]: 25/01/2023

[24] Turk, M., and Pentland, A.: Eigenfaces for recognition. *Journal of cognitive neuroscience*, 3(1), 71-86 (1991). <https://doi.org/10.1162/jocn.1991.3.1.71>

[25] Kirby, M., Sirovich, L.: Application of the karhunen-loeve procedure for the characterization of human faces. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 12(1), 103–108 (1990). <https://doi.org/10.1109/34.41390>

Integrating Radiograph Normalization Preprocessing and Discriminative Feature Selection for Efficient and Automated Pneumonia Detection

Salvador E. Ayala-Raggi, Angel Ernesto Picazo-Castillo, Aldrin Barreto-Flores,
and José Francisco Portillo-Robledo

Facultad de Ciencias de la Electrónica, Benemérita Universidad Autónoma de
Puebla, Puebla, México
saraggi@gmail.com, a.picazo.2505@gmail.com, aldrin.barreto@correo.buap.mx,
francisco.portillo@correo.buap.mx

Abstract. This paper introduces a technique for the detection of Viral Pneumonia using automatic localization, followed by pose and scale normalization of the specific region of interest (lungs) in chest radiographs. This method employs PCA and weighted K-NN regression. Our proposed approach includes estimating corner positions within the region of interest through interpolation, then mapping the image within that identified region onto a standardized fixed-size template. The primary goal is to achieve uniformity among training images in terms of position, angular pose, scale, and contrast, effectively aligning them. Subsequently, the eigenfaces method is employed to extract a reduced set of principal features from the normalized images. Among these PCA-derived features, those exhibiting the highest between-class discrimination capability are chosen using the Fisher criterion. Our results highlight the effective synergy achieved by integrating our lung region alignment technique with the meticulous selection and weighting of the most discriminative PCA features. This synergy is sufficient to achieve peak accuracies of 95.6% and 97.3% in classifying Viral Pneumonia radiographs using conventional classifiers, specifically weighted K-NN and MLP, respectively. Notably, our findings demonstrate that, in contrast to convolutional neural networks, a simpler technique can yield comparable classification results.

Keywords: K-Nearest Neighbors, Image Classification, Fisher Discriminant Criterion, Viral Pneumonia, Multilayer Perceptron

1. Introduction

Pneumonia is a lung disease caused by bacteria and viruses; a person can be infected through the air, saliva, or mucus. Furthermore, children and the elderly are at a higher risk of contracting it, according to [6]. Currently, various methods exist for detecting this disease, such as tomography, chest X-rays, and ultrasounds. However, tomography is more expensive than an X-ray, and ultrasound

is not always available or affordable. Hence, X-rays prove to be a more common detection method [1,2,23,38,27].

Presently, there exist datasets accessible containing labeled radiographs, which can be employed to train diverse machine learning algorithms [2]. The establishment of these repositories has been a cooperative endeavor involving establishments and domain-specialist medical professionals [33,30,26]. Nevertheless, the obstacle lies in the absence of consistency in the area of interest (pulmonary region) within these images. Some radiographs encompass redundant or unrelated data for categorization, such as supplementary bodily components or objects obscuring the thoracic area. This can negatively impact the precision metrics of categorization algorithms [5,10].

In this work, we aim to demonstrate the hypothesis that aligning the region of interest in both the training images and the test image, such that the anatomical structures within the lungs are positionally consistent across all images, can enable simple and conventional classification methods like K-NN or MLP to achieve better accuracy results, provided that a reliable feature reduction method like PCA is employed in conjunction with a feature selection process based on their discriminatory capability.

To this end, we propose applying two consecutive processes. The first process involves the detection and normalization of the lung region, ensuring that the images within the lung region exhibit the same alignment, location, scale, and improved contrast as much as possible. In the second process, the "Eigenfaces" method (PCA) will be applied to the aligned regions to obtain a reduced set of statistically independent features. Finally, based on the Fisher criterion [35], we propose performing a selection of the features that best discriminate between classes. Using this set of optimal features and a traditional classifier such as K-NN or MLP, the classification accuracy will be measured.

This work is divided into four parts. Part 1 discusses the related work and the utilized database. Part 2 describes and presents the algorithm called "Lung Finder Algorithm" (LFA) for the normalization procedure. Part 3 presents the theory of "Eigenfaces" and Fisher linear discriminant, as well as the feature weighting applied in our analysis for the normalized image features. Finally, in Part 4, the precision metrics are compared when utilizing our methodology with the weighted K-Nearest Neighbors (K-NN) classifier and the Multilayer Perceptron [9].

1.1. Related Work

Currently, various methodologies have been developed for classification of chest radiographs, as evidenced in previous studies [17,13,28,11,4,31,37]. These methodologies make use of deep learning algorithms or traditional machine learning classifiers [7,8], and have reported high levels of classification accuracy, greater than 96%. However, the architectures employed in these algorithms still face challenges in achieving a reliable classification of COVID-19 [32], as their accuracy decreases when tested with other datasets different from those used for training. This raises the need of exploring new proposals for normalizing and aligning the

lungs region before classifying, instead of just facing the problem by training classifiers like CNNs with a large number of of different datasets, to cope with the bias imposed by a particular one. Efficient non CNN-based works have been proposed too, as in [3], where a Multilayer Perceptron (MLP) and an architecture based on image involution were used, which proposes kernels similar to CNNs but shares their weights dynamically in all dimensions, thus reducing the number of multiplications necessary for the calculations. The former obtained a maximum classification accuracy of 98.31%. Feature selection has proven to be effective in increasing classification accuracy in other works, as observed in a study on [20] which used support vector machines to recognize the orbit axis of the sensors, as in another study [29] where it was also possible to classify the frequencies of an encephalogram. Furthermore, in a work carried out by Chengzhe et al. [21], the K-NN algorithm was applied successfully. Several studies have shown that image normalization improves classification results. In a study on kidney radiographs [10], the best results were obtained using CNN and image normalization techniques. Also, in another [19] work, different normalization techniques were used on different types of radiographs to improve image classification. It is important to highlight that the results of our work are not intended to devalue CNNs in image classification, but rather to present an alternative option, and to demonstrate that image alignment and a proper feature selection technique can produce results comparable to the most commonly used algorithms. in the state of the art. In the table 1 we show the comparison of the different pre-processing methods used in some published works [3,20,29,21,10,19]

Table 1. Comparison of the different preprocessing methods from related works

Authors	Image Normalization	Features selection	Classifier	Accuracy
Changawala et al., (2021)	Not Used	Not Used	MLP (Involution)	98.31%
Liu et al., (2023)	Not Used	Used	SVM	100%
Park et al.,(2015)	Not Used	Used	SVM	93.5%
Lv et al.,(2022)	Not Used	Used	KNN	96.14%
Gadermayr et al., (2017)	Used	Not Used	SVM	97%
Kociolek et al.,(2020)	Used	Used	SVM	96%

1.2. Data set of radiographic images

The database used for this work was "COVID-19 Radiography Database" [4,31] from kaggle. This data set was selected because it has been used in other similar works[25,15]. The content of this data set is 6012 images already labeled as pulmonary opacity (other lung diseases), 1345 as viral pneumonia, 10192 as normal, and finally 3616 as COVID-19.

2. Overview of the Lung Finder Algorithm (LFA)

The goal of this algorithm is to locate the lungs in the radiographs, and it consists of a training and testing stage, as shown in figure 1. During the training stage, 400 images from the Pneumonia, COVID-19, and Normal classes were randomly selected from the data set. Histogram equalization (HE) [12,24] was applied to all images and regions of interest were manually labeled by placing 4 provisional landmarks easily located by a human user. It was agreed that two of them would be located, one in the middle of the cervical vertebrae just at the upper limit of the lungs, and the other also on the spine but below where the lung region ends. The other two provisional landmarks are forced to the user to place them on a imaginary straight line perpendicular to the spine that intersects it just in the middle of the two previous landmarks. These last two landmarks are located in the left and right sides of lung region. Finally, and by using these 4 provisional positions, we compute 4 final and permanent landmarks at the corners of the rectangular lung region. On the other hand, ten new images randomly rotated and displaced were then generated for each labeled image to increase the data set and have an *augmented dataset*. Next, a dimensionality reduction to this set of 4400 images was applied using the "Eigenfaces" method based on Principal Component Analysis (PCA) [39,18].

During the test stage, and after a contrast improvement (H.E.), a new image is projected to the "Eigenfaces" linear subspace in order to convert it to a compact few dimensions vector which is compared via euclidean distance with each of the 4000 examples contained within the augmented dataset to find k nearest neighbors $k - NN$. The landmarks associated with these k most similar images from the augmented dataset are used to estimate the 4 landmarks of the test image by interpolation. These predicted landmarks are the coordinates of the corners of the lung ROI which can be used to warp the inside region to a standard template of fixed size.

2.1. Coordinates labeling for the LFA training stage

Each of the images selected for this stage requires a manual labeling where the region of interest of the lungs is delimited by a set of coordinates. These points or landmarks become the labels used by a regression weighted K-NN to predict the corner coordinates of the novel image. The coordinates the lung region are shown in figure 2, and consist of four points: $Q1(x1,y1)$, $Q2(x2,y2)$, $Q3(x3,y3)$ and $Q4(x4,y4)$. $Q1$ and $Q2$ represent the length of the lungs, while $Q3$ and $Q4$ represent their width. In total, 400 images were labeled manually.

The labeling process is shown in figure 3. First, the $Q1$ point at the top of the lungs is manually located, using the spine as reference. The $Q2$ point is then placed at the bottom of the lungs. When the points $Q1$ and $Q2$ are placed, a straight line connecting them automatically appears, and at the midpoint of this line a perpendicular line is drawn containing the points $Q3$ and $Q4$. These last two points are constrained to be placed by the user only along the perpendicular




Fig. 1. Lung Finder Algorithm description. During the training phase, 400 images were tagged with their coordinates. PCA was applied to reduce the dimensionality of the images. In the testing phase, an example radiograph is provided as input, and the algorithm extracts the region of interest as the output. During the test phase, the test image is compared with its nearest neighbors to interpolate its coordinates. Finally, the algorithm outputs the extracted region of interest in a new image.




Fig. 2. Example of an array of coordinates Q1, Q2, Q3, and Q4 on a radiograph.

line, and may have a different distance from the midpoint of the Q1Q2 line, due to the fact that the lungs are not symmetrical to each other.

2.2. Data Augmentation

Data augmentation is used in various machine learning tasks, such as image classification, to expand a limited database and avoid overfitting [22,34,19]. In the case of our algorithm, we have used a large dataset [4,31]. However, in order to have a set with ROI coordinates sufficiently varied we decided to generate artificial examples based on a randomly selected set, 400 images extracted from original set. The additional artificial images were generated by producing random translations and rotations of the original images. Ten additional artificial images were created from each of the original 400, resulting in a total of 4400 images. First, it was necessary to define the range of operations on the images. For rotation, we set a range of -10 to 10 degrees, suggested by [31], and for translation a range from -5 to 5 pixels. These values were calculated by analyzing the coordinates of the 400 manually labeled images. In summary, the LFA training set contains 4400 images where the coordinates of the landmarks are




Fig. 3. Sequential placement of the points Q. First Q1 is placed, then Q2 so that Q3 and Q4 appear on the perpendicular line that crosses the midpoint of the line Q1Q2. Finally, Q3 and Q4 are adjusted.

normal distributed. Figure 4 shows an example of artificial images with their corresponding landmarks.




Fig. 4. Example of artificial images during data augmentation, applying translation and rotation operations.

2.3. Estimating the corner coordinates of the lung region by regression

As shown in figure 1, in the test stage a new image is introduced from which it is desired to obtain its region of interest. Contrast enhancement and feature reduction are automatically applied to the test image by projecting it onto the "Eigenfaces". The weights obtained in this projection are used in the "weighted regression K-NN" algorithm to find the most similar neighbors in the "Eigenfaces" space, using the Euclidean distance. In order to reduce the computational cost, the calculations are performed in a 64x64 resolution.

Once the nearest neighbors have been identified, a regression is performed using the coordinates of the ROIs of these neighbors with the aim of predicting the coordinates of the lungs in the test image. For this, the regression equations (1 and 2) are used, which are applied to each coordinate, either x or y, of each Q landmark, until completing the entire set of landmarks (Q1, Q2, Q3 and Q4). The regression equations are detailed below

$$x_i = \frac{1}{k} \sum_{i=1}^k x_{ni} \quad (1.)$$

$$y_i = \frac{1}{k} \sum_{i=1}^k y_{ni} \quad (2.)$$

2.4. Image warping

Once the coordinates are obtained through regression, a Warping operation [36] is used to extract the region of interest. In figure 5, examples of different test radiographs from the data set are presented along with their automatically estimated ROI coordinates of provisional landmarks (red dots). The calculated coordinates are geometrically transformed to obtain the corners of the ROI (final landmarks depicted as blue dots) that are used in the Warping operation towards a standard fixed size template. On the right side of each image the normalized image resulting from the LFA is shown.




Fig. 5. Two examples of new images with their estimated ROI coordinates used to warp the inside region towards a fixed and normalized template.

3. Features reduction and selection

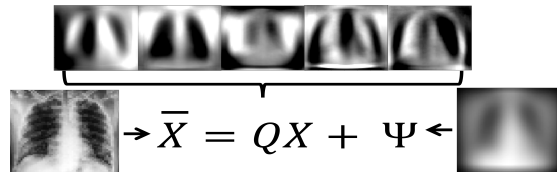
After using the LFA on all radiographs in the data set to extract all regions of interest, these new images undergo additional preprocessing before being processed by a classifying algorithm. For our work, we propose the use of [39,18] Eigenfaces as a feature reduction method. In addition, we incorporated a statistical analysis of these features using Fisher's linear discriminant in order to preserve only the most discriminating features and weighing each of them according to their power of discrimination between classes. Together these two methods ensure obtaining a reduced number of discriminant features suitable for efficient classification using traditional classifiers.

3.1. Eigenfaces for dimensionality reduction

Eigenfaces [39],[18] is based on principal component analysis (PCA) and its objective is to reduce the dimensionality of the images in the [16] dataset. Because each pixel becomes a dimension or feature to be analyzed, processing 256x256 images can be time consuming. On the other hand, a large number of

features, in comparison to a smaller number of training examples, could produce missclassification when euclidean distance based approaches as k-NN are used.

The resulting eigenfaces are sorted according to the greater variances of the training set, and can be used to reconstruct every image in the training set as a linear combination of them. Because the greatest amount of variance is concentrated in the first eigenfaces, we can use only a few number of them to efficiently represent all the training images and even novel ones. Thus, every normalized image from the training set can be represented with this compact set of features. Figure 6 shows the Eigenfaces equation, and the matrix Q which columns are the Eigenfaces. The *eigenfaces* method works better and is capable of concentrating more variance in a less number of eigenfaces when training images are more similar. In our case, the normalized images are more similar to each other than the original images from the dataset. For this reason, the number of useful PCA features is necessarily reduced when using the proposed LFA.



$$\rightarrow \bar{X} = QX + \Psi \leftarrow$$

Fig. 6. Reconstructed image (left) is computed as a linear combination of the columns of matrix Q (in the middle) plus the mean image (right)

3.2. Using the Fisher discriminant to reduce the number of useful features

Fisher discriminant criterion also known as Fisher ratio FR has been used in Linear Discriminant Analysis for finding a linear projection of features that maximizes the separation between classes. Typically, only one important feature survives this process in two classes problems. However, since the PCA features are to some degree independent, we can use, in a naive fashion, the fisher ratio as a measure of separation between classes for a each feature.

This process is done by evaluating each feature individually, and making sure that the means of the observations in each class are as far apart as possible, while the variances within each class are as small as possible. Using this analysis, it is possible to select a number greater than 2 of those features obtained by the Eigenfaces method that best discriminate the classes in the data set [35]

The FR has been used in works such as the one mentioned in [14], and we denoted it as J. The FR formula is found in equation 3.

$$J_i = \frac{(\mu_{ic_0} - \mu_{ic_1})^2}{\sigma_{ic_0}^2 + \sigma_{ic_1}^2} \quad (3.)$$




Fig. 7. Example of frequency distributions for each class. The discriminative capability of a feature can be visually assessed by the separation between the means of the histograms. The pair of histograms on the right shows a greater separation, indicating higher discrimination between classes. Conversely, the pair of histograms on the left exhibits lower discrimination.

3.3. The Fisher Ratio as a weight for each feature

We propose to use the FR value as a weigh for each feature, in such a way that those features that possess a greater capacity for discrimination are amplified.

As a first step we standardize all selected features in order to give them a uniform relevance. Then, we calculate $\rho_K = \sqrt{J_K}$ for each feature k. Next, we normalize ρ_K as shown in Eq. 4.

$$\varrho_k = \frac{\rho_k}{\sum_{i=1}^k \rho_i} \quad (4.)$$

Finally, each ϱ_k is used to weigh all the standardized observations for the feature k.

4. Experiments Setup

In this work, the weighted K-NN and MLP algorithms were used for classification. Several experiments were conducted to compare the impact of different image preprocessing and feature enhancement algorithms on classification accuracy. The algorithms used in the training and testing stages included LFA for

image normalization and preprocessing, Eigenfaces for dimensionality reduction, FR for selection of the best features, and W for weighting the features based on their discriminative capacity between classes. These two algorithms together aim to improve the discriminative ability of the features across classes. A total of five experiments were conducted for each classifier, which are described in Figure 8.

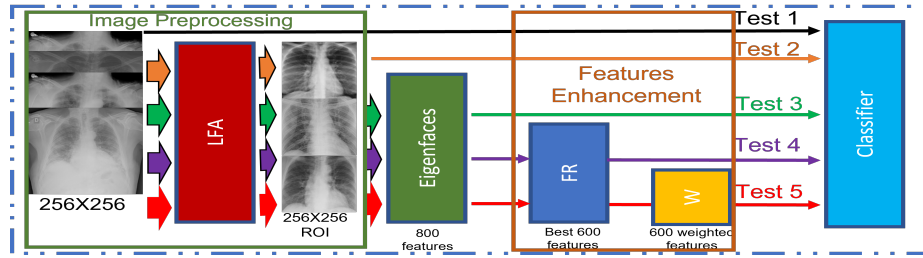


Fig. 8. Graphical representation of the different experiments conducted in image preprocessing. Each arrow represents a sequence of algorithms that may include image preprocessing or feature enhancement. A classification accuracy value is calculated for each arrow.

A total of 1300 COVID-19 images and 1300 normal images, all of size 256x256 pixels, were used. The region of interest was extracted from these images using the LFA algorithm, forming a bank of normalized images. The images were divided into 2000 training images, with 1000 from each class. For the testing phase, 600 images were selected, with 300 from each class. In experiments 1 and 2, 65,536 pixels, which constitute all the pixels of the images, were used. For experiments 3, 4, and 5, 600 features were employed.

For the MLP topology, 4 hidden layers with 120 neurons each and a single neuron in the output layer were utilized. The training was conducted for 100 epochs.

5. Experimental Results

Various values were tested for the parameter K in the weighted K-NN, and it was determined that the optimal value is 11. Conversely, experiments were conducted with various topologies and number of epochs in the MLP, yet no notable enhancements in classification precision were detected. The classification accuracy results for all experiments of each classifier are displayed in Table 2.

Additional tests were conducted in Experiment 5, varying the number of features for both classifiers. However, it was found that 600 is the optimal number of features for both classifiers. Furthermore, Experiment 5 underwent cross-validation to demonstrate the consistency of the proposed set of algorithms in this work. Table 3 displays the results of the 5 tests, along with the average and standard deviation for each classifier.

Table 2. Results of the Weighted K-NN and the MLP for the experiments using different preprocessing methods

Classifier	E1	E2	E3	E4	E5
Weighted K-NN	82%	88%	88.3%	92.3%	95.6%
MLP	86%	90.8%	91%	93%	97.3%

Table 3. Results of Weighted K-NN and MLP for cross-validation.

Classifier	Test 1	Test 2	Test 3	Test 4	Test 5	Mean	Std
Weighted K-NN	95.6%	94.8%	95%	94%	95.2%	94.92%	0.593
MLP	97%	97.3%	96.4%	97%	96.8%	96.9%	0.331

6. Discussion of Results

For both classifiers, the following statements can be made regarding the experiments conducted in image preprocessing:

1. Experiment one, where images undergo no preprocessing, generally displays the worst results.
2. Experiment two illustrates that image normalization improves results compared to experiment one.
3. In experiment three, where an image representation is projected onto the Eigenfaces space, no noteworthy enhancement is discernible.
4. Experiment four highlights the importance of feature selection that effectively separates classes using FR, resulting in improved accuracy.
5. Experiment five showcases the effectiveness of our algorithm sequence, which includes image normalization, feature selection, and weighting, yielding the best results.

Furthermore, the results exhibit robust consistency with minimal variability during cross-validation. Finally, the MLP achieved accuracy results that can compete with other state-of-the-art algorithms for classifying chest X-ray images.

7. Conclusions

In this paper, we have introduced a technique for the automatic detection and normalization of the Region of Interest (ROI) in chest radiographs. This approach is complemented by a feature selection method grounded in Fisher's criterion (FR) and utilizes PCA for automated COVID-19 detection. Through this approach, a reduced set of highly discriminative features is extracted. The outcomes underscore that the combination of both ROI alignment and feature selection processes leads to a significant improvement in classification accuracy. Notably, this improvement is evident when utilizing conventional classifiers such as weighted K-NN and MLP. These enhanced features demonstrate a notably superior classification capacity in comparison to the original pixel values. The

reliability of the reported results is further solidified by the incorporation of cross-validation techniques in their acquisition.

The contributions of this study encompass a method for normalizing the ROI in lung images and a technique for selecting highly discriminative features using FR. Our approach achieves accuracy values that compete with other state-of-the-art works employing CNN-based techniques.

For future work, the ROI normalization technique can be applied to other databases and for the detection of other lung diseases. Additionally, the feature selection and weighting approaches can be tested to enhance the accuracy of other classification algorithms. Finally, we provide the link to download and use the LFA code.

[CODE: <https://github.com/picazo07/LFA.git>]

References

1. Alzahrani, S.A., Al-Salamah, M.A., Al-Madani, W.H., Elbarbary, M.A.: Systematic review and meta-analysis for the use of ultrasound versus radiology in diagnosing of pneumonia. *Crit Ultrasound J* **9**(1), 6 (Dec 2017). <https://doi.org/10.1186/s13089-017-0059-y>
2. Amatya, Y., Rupp, J., Russell, F.M., Saunders, J., Bales, B., House, D.R.: Diagnostic use of lung ultrasound compared to chest radiograph for suspected pneumonia in a resource-limited setting. *Int J Emerg Med* **11**(1), 8 (Mar 2018). <https://doi.org/10.1186/s12245-018-0170-2>, [clinicalTrials.gov/NCT02949141](https://clinicaltrials.gov/NCT02949141)
3. Changawala, V., Sharma, K., Paunwala, M.: Averting from convolutional neural networks for chest x-ray image classification. In: 2021 IEEE International Conference on Signal Processing, Information, Communication and Systems (SPICSCON). pp. 14–17 (2021). <https://doi.org/10.1109/SPICSCON54707.2021.9885316>
4. Chowdhury, M.E.H., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M.A., Mahbub, Z.B., Islam, K.R., Khan, M.S., Iqbal, A., Emadi, N.A., Reaz, M.B.I., Islam, M.T.: Can AI help in screening viral and COVID-19 pneumonia? *IEEE Access* **8**, 132665–132676 (2020). <https://doi.org/10.1109/access.2020.3010287>
5. Cleophas, T., Zwinderman, A.: *Machine Learning in Medicine: Part Two. Machine Learning in Medicine*, Springer Netherlands (2013), <https://books.google.com.mx/books?id=ektozphE8GYC>
6. in Data, O.W.: Covid-19 data explorer. <https://ourworldindata.org/explorers/coronavirus-data-explorer> (2022), accessed: February 2022
7. Do, T.N., Le, V.T., Doan, T.H.: Svm on top of deep networks for covid-19 detection from chest x-ray images. *Journal of information and communication convergence engineering* **20**, 219–225 (09 2022). <https://doi.org/10.56977/jicce.2022.20.3.219>
8. El-kenawy, E.S., Mirjalili, S., Ibrahim, A., Alrahmawy, M., Elsaid, M., Mounir, R., Eid, M.: Advanced meta-heuristics, convolutional neural networks, and feature selectors for efficient covid-19 x-ray chest image classification. *IEEE Access* **PP**, 1–1 (02 2021). <https://doi.org/10.1109/ACCESS.2021.3061058>
9. Ertel, W., Black, N.: *Introduction to Artificial Intelligence. Undergraduate Topics in Computer Science*, Springer International Publishing (2018), <https://books.google.com.mx/books?id=Z4kCuAEACAAJ>

10. Gadermayr, M., Cooper, S., Klinkhammer, B., Boor, P., Merhof, D.: A quantitative assessment of image normalization for classifying histopathological tissue of the kidney. pp. 3–13 (08 2017)
11. Gazda, M., Plavka, J., Gazda, J., Drotar, P.: Self-supervised deep convolutional neural network for chest x-ray classification. *IEEE Access* **9**, 151972–151982 (2021). <https://doi.org/10.1109/access.2021.3125324>
12. Gonzalez, R., Woods, R.: *Digital Image Processing, Global Edition*. Pearson Education (2018), <https://books.google.com.mx/books?id=p74oEAAAQBAJ>
13. Hamza, A., Attique Khan, M., Wang, S.H., Alhaisoni, M., Alharbi, M., Hussein, H.S., Alshazly, H., Kim, Y.J., Cha, J.: Covid-19 classification using chest x-ray images based on fusion-assisted deep bayesian optimization and grad-cam visualization. *Frontiers in Public Health* **10**, 1046296 (11 2022). <https://doi.org/10.3389/fpubh.2022.1046296>
14. Ibis, E.: *Sistema de aprendizaje automático para la detección de neumonía*. Master's thesis, Benemérita Universidad Autónoma de Puebla, Puebla, México (2022)
15. Islam, N., Ebrahimzadeh, S., Salameh, J.P., Kazi, S., Fabiano, N., Treanor, L., Absi, M., Hallgrimson, Z., Leeflang, M.M., Hooft, L., van der Pol, C.B., Prager, R., Hare, S.S., Dennie, C., Spijker, R., Deeks, J.J., Dinnes, J., Jenniskens, K., Korevaar, D.A., Cohen, J.F., Van den Bruel, A., Takwoingi, Y., van de Wijgert, J., Damen, J.A., Wang, J., McInnes, M.D.: Thoracic imaging tests for the diagnosis of covid-19. *Cochrane Database Syst Rev* **3**(3), CD013639 (Mar 2021). <https://doi.org/10.1002/14651858.CD013639.pub4>
16. Jolliffe, I.: *Principal Component Analysis*. Springer Series in Statistics, Springer (2002), <https://books.google.com.mx/books?id=.olByCrhjwIC>
17. Khan, A., Khan, S., Saif, M., Batool, A., Sohail, A., Khan, M.: A survey of deep learning techniques for the analysis of covid-19 and their usability for detecting omicron. *Journal of Experimental and Theoretical Artificial Intelligence* (02 2022). <https://doi.org/10.1080/0952813X.2023.2165724>
18. Kirby, M., Sirovich, L.: Application of the karhunen-loeve procedure for the characterization of human faces. *IEEE Transactions on Pattern Analysis and Machine Intelligence* **12**(1), 103–108 (1990). <https://doi.org/10.1109/34.41390>
19. Kociolek, M., Strzelecki, M., Obuchowicz, R.: Does image normalization and intensity resolution impact texture classification? *Computerized Medical Imaging and Graphics* **81**, 101716 (03 2020). <https://doi.org/10.1016/j.compmedimag.2020.101716>
20. Liu, W., Zheng, Y., Zhou, X., Chen, Q.: Axis orbit recognition of the hydropower unit based on feature combination and feature selection. *Sensors* **23**(6) (2023). <https://doi.org/10.3390/s23062895>
21. Lv, C., Lu, Y., Lu, M., Feng, X., Fan, H., Xu, C., Xu, L.: A classification feature optimization method for remote sensing imagery based on fisher score and mrmr. *Applied Sciences* **12**, 8845 (09 2022). <https://doi.org/10.3390/app12178845>
22. Mikołajczyk-Bareła, A., Grochowski, M.: Data augmentation for improving deep learning in image classification problem. pp. 117–122 (05 2018). <https://doi.org/10.1109/IIPHDW.2018.8388338>
23. Moberg, A., Talés, U., Garvin, P., Fransson, S.G., Falk, M.: Community-acquired pneumonia in primary care: Clinical assessment and the usability of chest radiography. *Scandinavian journal of primary health care* **34**, 1–7 (02 2016). <https://doi.org/10.3109/02813432.2015.1132889>

24. Moeslund, T.B.: Introduction to Video and Image Processing: Building Real Systems and Applications. Undergraduate Topics in Computer Science, Springer London (2012), <https://books.google.com.mx/books?id=Ph5Jw-iGMlkC>
25. Muljo, H.H., Pardamean, B., Purwandari, K., Cenggoro, T.W.: Improving lung disease detection by joint learning with covid-19 radiography database. *Communications in Mathematical Biology and Neuroscience* **2022**(1), 1–24 (2022)
26. Mustafa Ghaderzadeh, M.A., Asadi, F.: X-ray equipped with artificial intelligence: Changing the COVID-19 diagnostic paradigm during the pandemic. *BioMed research international* **2021**, 9942873 (2021). <https://doi.org/10.1155/2021/9942873>
27. Niederman, M.S.: Community-acquired pneumonia. *Annals of Internal Medicine* **163**(7), ITC1–ITC16 (2015)
28. Nillmani, Sharma, N., Saba, L., Khanna, N.N., Kalra, M.K., Fouda, M.M., Suri, J.S.: Segmentation-based classification deep learning model embedded with explainable ai for covid-19 detection in chest x-ray scans. *Diagnostics* **12**(9) (2022). <https://doi.org/10.3390/diagnostics12092132>
29. Park, S.H., Lee, S.G.: A method of feature extraction on motor imagery eeg using fld and pca based on sub-band csp. *Journal of KIISE* **42**, 1535–1543 (12 2015). <https://doi.org/10.5626/JOK.2015.42.12.1535>
30. Qin, C., Yao, D., Shi, Y., Song, Z.: Computer-aided detection in chest radiography based on artificial intelligence: a survey. *BioMedical Engineering OnLine* **17**(1), 113 (2018). <https://doi.org/10.1186/s12938-018-0544-y>
31. Rahman, T., Khandakar, A., Qiblawey, Y., Tahir, A., Kiranyaz, S., Abul Kashem, S.B., Islam, M.T., Al Maadeed, S., Zughaier, S.M., Khan, M.S., Chowdhury, M.E.: Exploring the effect of image enhancement techniques on covid-19 detection using chest x-ray images. *Computers in Biology and Medicine* **132**, 104319 (2021). <https://doi.org/https://doi.org/10.1016/j.compbiomed.2021.104319>, <https://www.sciencedirect.com/science/article/pii/S001048252100113X>
32. Ridzuan, M., Bawazir, A.A., Navarette, I.G., Almakky, I., Yaqub, M.: Self-supervision and multi-task learning: Challenges in fine-grained covid-19 multi-class classification from chest x-rays (2022)
33. Salvatore, C., Interlenghi, M., Monti, C.B., Ippolito, D., Capra, D., Cozzi, A., Schiaffino, S., Polidori, A., Gandola, D., Ali, M., Castiglioni, I., Messa, C., Sardanelli, F.: Artificial intelligence applied to chest x-ray for differential diagnosis of covid-19 pneumonia. *Diagnostics (Basel)* **11**(3), 530 (2021). <https://doi.org/10.3390/diagnostics11030530>
34. Shorten, C., Khoshgoftaar, T.M.: A survey on image data augmentation for deep learning. *Journal of Big Data* **6**(1), 60 (Jul 2019). <https://doi.org/10.1186/s40537-019-0197-0>
35. Silva, T.S.: An illustrative introduction to fisher’s linear discriminant. <https://sthalles.github.io> (2019), <https://sthalles.github.io/fisher-linear-discriminant/>
36. Szeliski, R.: *Computer Vision: Algorithms and Applications*. Springer-Verlag, Berlin, Heidelberg, 1st edn. (2010)
37. Talaat, A., Yousri, D., Ewees, A., Al-qaness, M.A.A., Damaševičius, R., El-sayed Abd Elaziz, M.: Covid-19 image classification using deep features and fractional-order marine predators algorithm. *Scientific reports* **10**, 15364 (09 2020). <https://doi.org/10.1038/s41598-020-71294-2>
38. Ticinesi, A., Lauretani, F., Nouvenne, A., Mori, G., Chiussi, G., Maggio, M., Meschi, T.: Lung ultrasound and chest x-ray for detecting pneumonia in an acute geriatric ward. *Medicine (Baltimore)* **95**(27), e4153 (Jul 2016). <https://doi.org/10.1097/MD.0000000000004153>

39. Turk, M., Pentland, A.: Eigenfaces for Recognition. *Journal of Cognitive Neuroscience* **3**(1), 71–86 (01 1991). <https://doi.org/10.1162/jocn.1991.3.1.71>