

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".

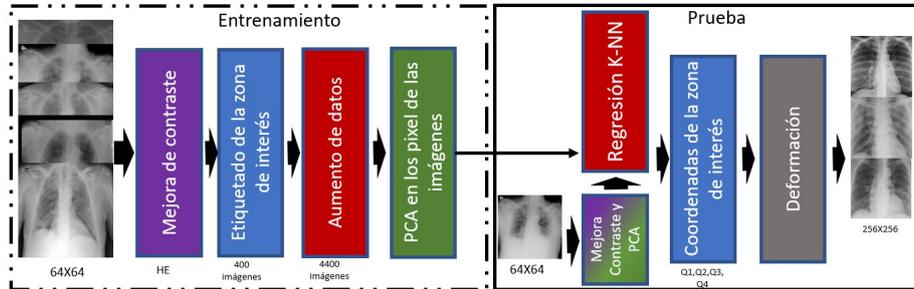


Fig. 2. Descripción del Algoritmo Localizador de Pulmones. En la entrada de la etapa de prueba se encuentra un ejemplo de radiografía y a la salida se tienen la región de interés ya extraída.

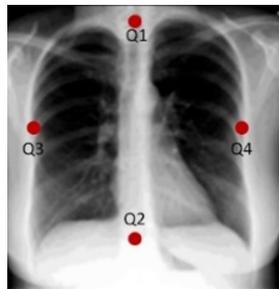


Fig. 3. Coordenadas Q1, Q2, Q3 y Q4 en una radiografía.

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 ecuación 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 ecuación 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.

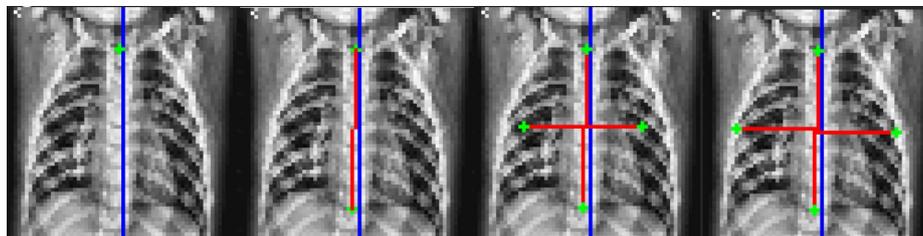


Fig. 4. Secuencia para la localización de los puntos Q, primero Q1 es localizado, después Q2 para que Q3 y Q4 aparezcan en la recta perpendicular que cruza por el punto medio de la recta Q1Q2. Finalmente, Q3 y Q4 son ajustados.

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.

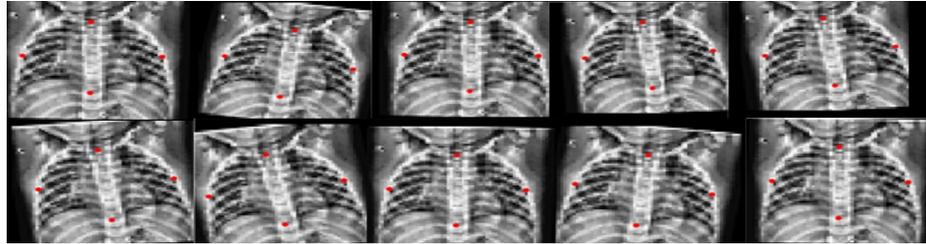


Fig. 5. Ejemplo de imágenes artificiales durante el aumento de datos.

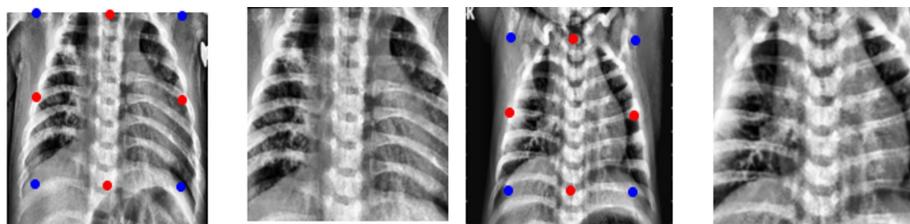


Fig. 6. Imágenes de ejemplo con sus regiones de interés ya extraídas.

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:

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

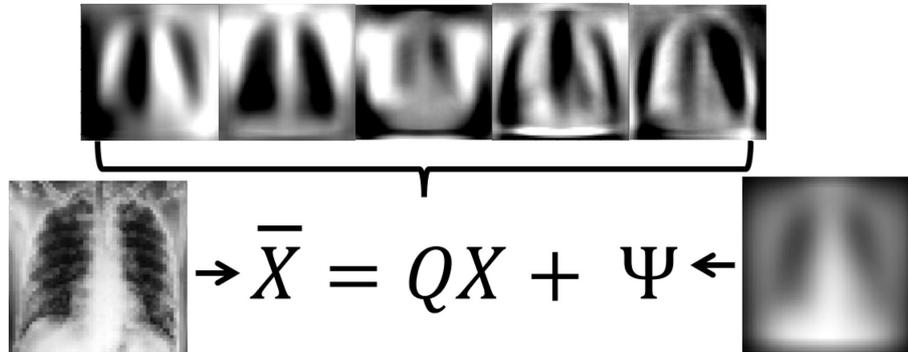


Fig. 7. Imagen de salida (Izquierda) como la combinación lineal de la matriz de Eigenfaces Q (medio) y la imagen de entrada más la cara media (derecha).

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

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.

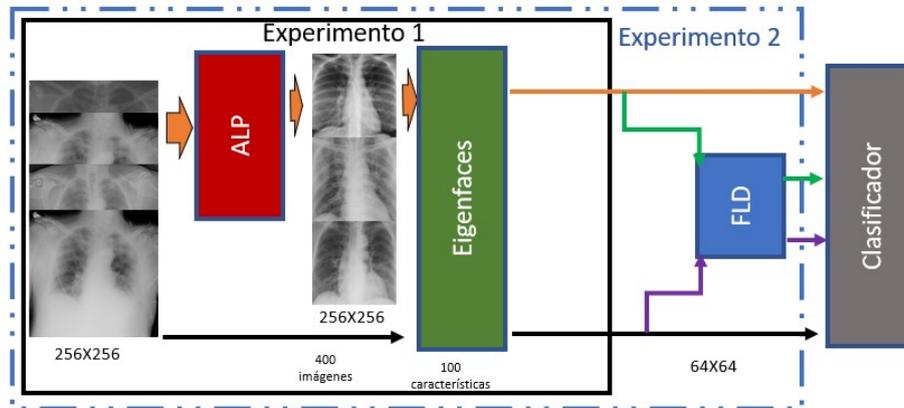


Fig. 8. Diagrama acerca de los dos experimentos. Cada flecha que llega al clasificador es una métrica de precisión y se realizará una comparación de todas.

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].

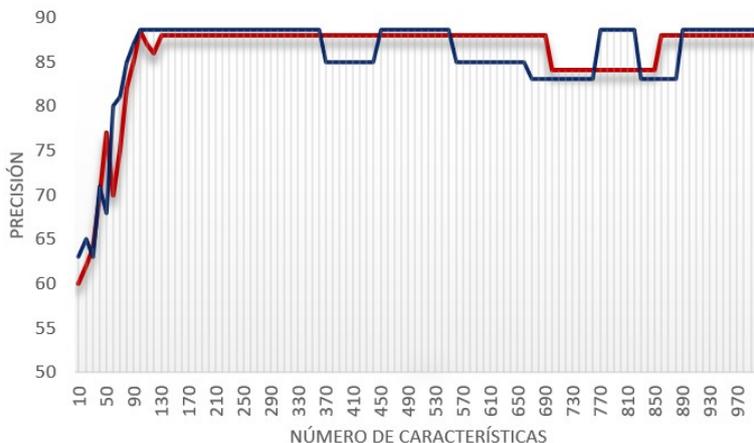


Fig. 9. Valores de precisión variando el numero de características. K-NN ponderado (Línea roja) y MLP (Línea azul).

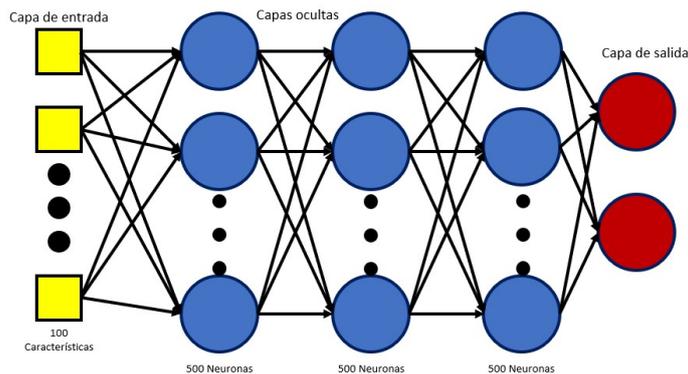


Fig. 10. Topología del MLP.

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)