

Detección y clasificación de neumonía en imágenes de Rayos X usando técnicas de preprocesamiento y Deep Learning

Victor Hugo Galindo-Ramirez, José Agustín Almaraz-Damian,
Clara Cruz-Ramos, Volodymyr Ponomaryov,
Rogelio Reyes-Reyes

Instituto Politécnico Nacional,
México

vgalindor1601@alumno.ipn.mx, vponomar@ipn.mx

Resumen. La radiografía de tórax es una herramienta utilizada en el diagnóstico médico, este tipo de imágenes se destacan por ser accesibles para la comunidad, proporcionando suficiente información de la región del tórax, para ser evaluadas por los especialistas, en caso de presentar alguna enfermedad. Además, debido a su simplicidad, la radiografía de tórax es la mejor opción contra las imágenes de tomografía computarizada (CT), ultrasonido (US) o resonancia magnética (MRI) en pacientes pediátricos. En este trabajo se propone un esquema de preprocesamiento el cual elimina las regiones de la imagen de Rayos X que no pertenecen a la caja torácica, como etiquetas generadas al realizar el estudio, entre otras. Después de procesar las antes mencionadas las imágenes, se procede a entrenar un modelo basado en la arquitectura de las Redes Neuronales Convolucionales. Finalmente, el sistema diseñado emplea el algoritmo Grad-CAM con el fin de proporcionar una imagen que contenga la representación perceptual de las características relevantes que fueron obtenidas para cada clase. El sistema ha demostrado un rendimiento similar en comparación con los métodos más avanzados, empleando métricas de calidad como Exactitud (Accuracy), Precisión, Sensibilidad y Métrica-F1.

Palabras clave: Clasificación, rayos x, aprendizaje profundo, neumonía, CNN.

Detection and Classification of Pneumonia in X-Ray Images Using Preprocessing Techniques and Deep Learning

Abstract. Chest X-ray imaging is a tool used in medical diagnosis, this type of image stands out against computed tomography (CT), ultrasound (US), or magnetic resonance imaging (MRI) in paediatric patients. Moreover, is accessible to the community and provides enough

information about the chest region to be evaluated by physicians. In this work, a preprocessing scheme is proposed to eliminate regions of the X-Ray image that do not belong to the thorax area, also known as the rib cage. This region also contains objects, such as labels, generated when the study is performed. After processing the aforementioned images, we proceed to train two models based on Convolutional Neural Network architectures. Finally, the designed system uses the Grad-CAM algorithm to provide an image that includes the perceptual representation of the relevant features obtained for each class. The system has shown similar performance compared with State-Of-The-Art methods, using quality metrics such as Accuracy, Precision, Sensibility, and F1-Score. Detection and Classification of Pneumonia in X-Ray images using preprocessing techniques and Deep Learning.

Keywords: Classification, x-ray, deep learning, pneumonia, CNN.

1. Introducción

En la actualidad, la tasa de mortalidad por Neumonía ha ido en aumento, principalmente en niños menores de cinco años, además la Organización Mundial de la Salud (OMS) estima que se reportan alrededor de 156 millones de casos en todo el mundo por año [10]. En México, el Instituto Nacional de Salud Pública (INSP) informó que se diagnosticaron 117 mil casos y 21 mil personas fallecieron por neumonía en los años 2017 y 2018 [31].

El Instituto Nacional de Estadística y Geografía (INEGI) en la Figura 1 presenta un estudio de las defunciones por neumonía por cada 10 mil habitantes entre los meses de Enero-Agosto (2011-2020) y de los años (2011-2019) donde el total de las muertes por influenza y neumonía que ascendieron a 29 mil casos, el 99% es representado por defunciones causadas por la neumonía [4].

Los sistemas asistidos por computadora (CAD) se utilizan para mejorar, detectar y extraer una Región de Interés (ROI) de la imagen digitalizada de un estudio clínico. Estos sistemas pueden ayudar a los médicos radiólogos especialistas a analizar dicha ROI de una manera rápida y precisa, reduciendo el tiempo de procesamiento y mejorando el tiempo de respuesta durante el tratamiento de un paciente.

El aprendizaje máquina o mejor conocido como Machine Learning [30] tiene el objetivo de desarrollar sistemas que aprendan a reconocer patrones automáticamente, por otro lado, el aprendizaje profundo o Deep Learning [12], es empleado para desarrollar sistemas computacionales inteligentes que demandan una gran cantidad de datos con el fin de clasificar imágenes.

Los sistemas CAD requieren de métodos que logren proporcionar ofrecer segunda opinión al especialista y poder emitir un diagnóstico. Dependiendo del objetivo del sistema, las técnicas de aprendizaje automático requieren características de tipo *handcraft*, las cuales están basadas en patrones perceptuales, estadísticos o médicos. Por el contrario, las técnicas de aprendizaje profundo

utilizan la información contenida en los datos ingresados, lo que permite extraer y aprender características que no se caracterizan como perceptuales, pero son relevantes para determinar si la imagen pertenece a una clase o no.




Fig. 1. Tasa de defunciones por influenza y neumonía por cada 10 000 habitantes Enero-Agosto (2011-2020) y cierre de año (2011-2019) obtenido de [4].

2. Estado del arte

El sistema propuesto por Jiang et al. [14] presenta un sistema el cual clasifica imágenes de Rayos X como entrada, para las arquitecturas InceptionResNetV2, Xception, DenseNet201, VGG19, el autor reporta que se obtiene el mejor resultado utilizando la arquitectura InceptionResNetV2 con un 94 % de exactitud.

Sánchez et al.[23] proponen un sistema el cual clasifica neumonía en imágenes de Rayos X, utilizando la arquitectura Xception y un subespacio basado en el análisis de componentes principales (PCA) el cual incrementa la exactitud a partir de pequeños dataset de entrenamiento, los autores reportan una exactitud del 96 % utilizando únicamente 600 imágenes.

Lujan et al.[17] desarrollan un sistema CAD basado en la arquitectura Xception empleando pesos previamente entrenados con el dataset de ImageNet Large Scale Visual Recognition Challenge (ILSVRC), mejor conocido como Imagenet [22]. Además, utilizan una técnica de preprocesamiento, la cual consiste en eliminar los bordes negros de las imágenes de Rayos X para mantener la mayor cantidad de información de la ROI.

Varela et al. [28] proponen un sistema que mediante una red neuronal artificial clasifica imágenes de Rayos X y de tomografía computarizada en tres clases: COVID-19, Neumonía y Normal, se extraen 129 características de tipo handcraft por cada una de las 750 imágenes, finalmente los autores reportan una exactitud del 97 %.

El sistema propuesto por Varela et al.[29] clasifica Neumonía utilizando una segmentación que por medio de algoritmos de tipo handcraft elimina regiones de la imagen quedando únicamente con ambos pulmones, posteriormente se utiliza una red neuronal modular, que consiste en entrenar y clasificar 40 características divididas en: histograma, Matriz de co-ocurrencia de niveles de grises (GLCM) y patrones locales binarios (LBP) respectivamente, la clasificación final es promediada de acuerdo con cada salida obtenida por los 3 tipos de características.




Fig. 2. Diagrama a bloques del sistema propuesto.

En este trabajo se presenta un sistema CAD de Rayos X para la detección de Neumonía, en el cual, se utiliza una técnica de procesamiento diseñada para extraer la región pulmonar con el fin de reforzar la extracción de patrones pertenecientes a la ROI. Posteriormente, la Imagen de la ROI se empleará para entrenar la arquitectura de Red Neuronal Convolutiva (CNN) Xception.

El sistema CAD propuesto se implementó en una PC con una GPU Nvidia® RTX 3090. Los experimentos emplearon el dataset 'Imágenes de Rayos X de tórax para la clasificación' propuesto en [15], se evalúa el rendimiento del sistema propuesto empleando las métricas de calidad: exactitud, especificidad, sensibilidad y métrica-F1 frente a los sistemas consultados en el Estado del Arte.

3. Sistema propuesto

El sistema CAD propuesto se conjunta de tres etapas principales: (a) Preprocesamiento, (b) Extracción de la ROI y (c) Clasificación. En la primera etapa se redimensionan las imágenes y se aplica una mejora de contraste.

En la segunda etapa, la caja torácica se segmenta y se extrae mediante el uso del algoritmo de contornos activos morfológicos y el algoritmo bounding box respectivamente. Finalmente, en la tercera etapa la imagen ROI es procesada por la Arquitectura CNN elegida, cuyas características son extraídas y aprendidas para clasificar imágenes Normales y de Neumonía. El diagrama a bloques conceptual del sistema CAD diseñado se presenta en la Figura 2.

3.1. Dataset Chest X Ray Images

El dataset proporcionado por la Universidad de California [15] contiene 5232 imágenes de Rayos X de tórax, las cuales se encuentran divididas en dos clases; neumonía y normal, proponiendo 234 imágenes normales y 390 de neumonía, las cuales son utilizadas para validar el desempeño del sistema.

En la Figura 3 se muestran dos imágenes de Rayos X, donde una de ellas contiene patrones radiológicos que se presentan en la neumonía, los cuales son: neumonía lobar, bronconeumonía, neumonía intersticial, neumonía redonda y neumonía por aspiración [21], por otro lado, la imagen normal no presenta patrones radiológicos.




Fig. 3. Muestras aleatorias del dataset para la clase: A) Imagen normal; B) Imagen de neumonía.




Fig. 4. Muestra aleatoria de la etapa de preprocesamiento: A) Imagen Original; B) Imagen Ecuilizada.

3.2. Preprocesamiento

Las imágenes originales de Rayos X de tórax $Img(i, j)$ proporcionadas por [15] no presentan un tamaño y el contraste de estas imágenes son relativamente bajos lo que afecta la calidad de la imagen en el diagnóstico. En este estudio, se

propone cambiar el tamaño de las imágenes $\text{Img}(i, j)$ a 400×400 píxeles con el fin de utilizar un tamaño de imagen homogéneo, además se aplica una ecualización adaptativa del histograma por contraste mejor conocido como CLAHE[20] para mejorar la calidad de la imagen. En la Figura 4 se observa la diferencia de contraste entre una imagen original y la misma imagen ecualizada Img_{Ec} que presenta ligera mejora de contraste.

3.3. Extracción de la ROI

La radiografía de tórax normalmente presenta etiquetas que contienen información adicional como por ejemplo, el nombre del paciente, la fecha del examen, el indicador del lado derecho-izquierdo de la radiografía, etc. En este trabajo se propone extraer la región de la caja torácica, la cual es donde está presente la neumonía. Se extrae esta área, con el propósito de obtener una imagen de región de interés (ROI) para garantizar que las características extraídas pertenezcan a la región pulmonar que es donde se presenta la neumonía.

Para generar la imagen procesada Img_{Ps} se deben de aplicar diferentes algoritmos *handcraft* a la imagen Img_{Ec} . Se requieren cuatro pasos para obtener las imágenes procesadas, primero se aplica una umbralización para generar una imagen binaria Img_{Bin} donde las regiones más claras de la imagen tomaran tonalidades blancas y las partes oscuras de la imagen tomaran tonalidades negras, esta umbralización se puede definir como:

$$V(i, j) = \begin{cases} 1, & \text{si } X(i, j) \geq th, \\ 0, & \text{si } X(i, j) < th, \end{cases} \quad (1)$$

donde $X(i, j)$ es el nivel de intensidad de la imagen de Rayos X en la posición (i, j) , $V(i, j)$ es el valor asignado en la posición i, j y th está definido por:

$$th = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n X(i, j), \quad (2)$$

donde $X(i, j)$ es el nivel de intensidad de la imagen de Rayos X en la posición (i, j) , a esta umbralización se le conoce en la literatura como umbralización por la media estadística. En el siguiente paso de la etapa de extracción de la ROI, se emplea el algoritmo de contornos activos morfológicos [5].

Para aplicar este algoritmo se emplean operaciones morfológicas como la erosión y la dilatación en una imagen binaria en lugar de resolver una PDE (Partial Differential Equations) y se denota como:

$$C_t = F \times N, \quad (3)$$

donde F es un escalar y N una superficie normal ya que desea observar la evolución de la curva C . La evolución de cualquier función $U(x, y)$, que incorpore la curva como uno de sus conjuntos de nivel es:

$$\frac{\partial u}{\partial t} = F \times |\nabla u|. \quad (4)$$

La PDE anterior para la curva de evolución es la siguiente:

$$\frac{\partial u}{\partial t} = \pm |\nabla u|, \quad \text{Cuando } F = \pm 1. \quad (5)$$

Algunos operadores morfológicos pueden ser expresados como PDE y se presentan de la siguiente manera:

– **Dilatación**

$$\lim_{h \rightarrow 0} \left(\frac{D_h u - u}{h} \right) = |\nabla u|, \quad (6)$$

$$\frac{\partial u}{\partial t} = |\nabla u|. \quad (7)$$

– **Erosión**

$$\lim_{h \rightarrow 0} \left(\frac{D_h u - u}{h} \right) = -|\nabla u|, \quad (8)$$

$$\frac{\partial u}{\partial t} = -|\nabla u|. \quad (9)$$

Por lo tanto, de la imagen Img_{Bin} se genera una máscara del área donde se encuentra contenido el pulmón $Mask$. A continuación, se aplica un filtro de media con una ventana de 21×21 píxeles a la imagen $Mask$ eliminando regiones que no forman parte del área pulmonar Img_{Mn} .

Finalmente, se extrae la caja torácica obteniendo Img_{Ps} . En la Figura 5 se muestra una comparación entre una imagen original y una procesada, donde se han eliminado las áreas insignificantes, es decir, que no aportan información; estas imágenes de procesadas ayudan a la CNN a extraer características de la región pulmonar.

3.4. Etapa de clasificación

En la siguiente sección, se presenta una breve discusión de la arquitectura Xception utilizada en el sistema y la metodología utilizada al emplearlas.

Transferencia de aprendizaje. Es una técnica que utiliza los pesos obtenidos por un sistema que fue entrenado para una tarea en general, estos pesos son transferidos a otro sistema para resolver una tarea particular y se define como:

Sea un dominio general D_g entrenado para una tarea general T_g y un dominio particular D_p con una tarea particular T_p . Transfer Learning mejora el aprendizaje de la función predictiva particular $f_p(\cdot)$ en el dominio D_p usando los conocimientos de D_g y la tarea T_g donde el dominio $D_g \neq D_p$ o la tarea $T_g \neq T_p$. En la Figura 6 se presenta un ejemplo visual del transfer learning para una tarea en particular.

Xception. Chollet et al.[6] propone la arquitectura Xception la cual está basada en la arquitectura Inception-V3, la diferencia radica en que Xception




Fig. 5. Comparación de las Imágenes de Rayos X A) Imagen original y B) Imagen procesada.




Fig. 6. Esquema de la técnica transfer learning.

Tabla 1. Hiperparámetros usados en la Arquitectura Xception CNN.

Arquitectura	Learning Rate	Decay	Batch size	Optimizador	Épocas
Xception	5×10^{-2}		16	SGD	100




Fig. 7. Arquitectura simplificada de Xception.

realiza convoluciones separables (Depth Wise Separable Convolutions) por cada canal de la imagen de entrada por lo que reduce las operaciones y el costo computacional de la red, el autor reporta una exactitud del 94% utilizando el conjunto de datos llamado Imagenet.

4. Resultados experimentales

4.1. Entorno experimental

El sistema CADx propuesto se implementó en una PC con una CPU Intel®Xeon E5 1230-V5, 24 GB de RAM, con una GPU NVIDIA RTX®3090 con 24 GB de RAM, ejecutando un sistema operativo Linux de 64 bits, Python 3.6, y las bibliotecas: TensorFlow 2.7[18] y scikit-image[3].

4.2. Hiperparámetros

Se utilizan las imágenes procesadas para entrenar la arquitectura CNN anteriormente mencionada. Además, obtenemos el mapa de activación de características mediante el algoritmo Grad-CAM para validar que las características extraídas pertenezcan a la región pulmonar respectivamente a cada clase. La Tabla 1 contiene los hiperparámetros empleados para la arquitectura CNN. El Learning Rate decay es expresado como:

$$Lrd = Lr_i \times D^{(s/ds)}, \quad (10)$$

donde Lr_i es la tasa de aprendizaje inicial, D es la tasa de caída s son los pasos, que aumentan en cada época y ds es el umbral de la tasa de caída de los pasos.

4.3. Métricas de evaluación

Evaluamos el rendimiento del sistema CAD propuesto considerando las siguientes métricas de evaluación: **Exactitud (Accuracy)**, **Precisión**, **Sensibilidad**, **Especificidad** y **Métrica-F1**. Estos criterios se describen en términos de tp , tn , fp y fn , que denotan verdadero positivo, verdadero negativo, falso positivo y falso negativo:

$$\text{Exactitud} = \frac{tp + tn}{tp + tn + fp + fn}. \quad (11)$$

El valor de la exactitud mide los casos en que el sistema clasifica correctamente utilizando el total de elementos evaluados, y se calcula como:

$$\text{Sensibilidad} = \frac{tp}{tp + fn}. \quad (12)$$

El valor de sensibilidad mide el número de elementos positivos que se clasifican correctamente, y se calcula como:

$$\text{Especificidad} = \frac{tn}{tn + fp}. \quad (13)$$

El valor de especificidad mide el número de elementos negativos que se clasifican correctamente, y se calcula como:

$$\text{Precision} = \frac{tp}{tp + fp}. \quad (14)$$

El valor de precisión mide el número de elementos que están correctamente clasificados entre el total de elementos positivos a evaluar, y se calcula como:

$$\text{Métrica-F1} = \frac{2tp}{2tp + fp + fn} \quad (15)$$

El valor de la Métrica-F1 mide la media armónica entre precisión y la sensibilidad.

4.4. Resultados y comparación

Para comparar el rendimiento del sistema propuesto con los sistemas descritos en el Estado del Arte, utilizamos métricas de evaluación y el algoritmo Grad-CAM para demostrar que utilizando las imágenes procesadas se puede extraer características significativas de neumonía en lugar de tomar características insignificantes en áreas como etiquetas, brazos, cuellos, etc. Los resultados expuestos en la Tabla 2 muestran que el sistema implementado mantiene un rendimiento similar al de otros sistemas existentes.

Finalmente, se emplea el algoritmo Grad-CAM [24], en los sistemas CAD presentados por Sánchez [23] y Lujan [17] presentan los mapas de calor para tener una aproximación a las regiones o patrones que se están tomando en cuenta para ser clasificadas como neumonía o normal. Los sistemas propuestos por Jiang [14] y Varela [28,29] no presenta ninguna validación de este tipo, por lo que la única comparación se realiza de forma cuantitativa.

La Figura 8 muestra la comparación entre cuatro imágenes Grad-CAM donde la imagen obtenida por Luján concentra su atención al área del corazón para clasificar neumonía, mientras que la imagen presentada por Sánchez [23] concentra toda la atención en una región perteneciente al hombro/brazo y lóbulo superior, del metodo propueso se puede observar que la imagen procesada enfoca la extracción de características dentro de la caja torácica tomando regiones como los alvéolos, lóbulo superior e inferior.

Tabla 2. Comparación del desempeño del sistema propuesto frente a sistemas encontrados en el Estado del Arte.

	Sistema Propuesto	Jiang[14]	Sánchez[23]	Lujan[17]	Varela[28]	Varela[29]
	Xception	Xception	Xception	Xception	ANN	ANN
Exactitud	91 %	92 %	96 %	87 %	97 %	99 %
Sensibilidad	91 %	-	95 %	99 %	-	98 %
Especificidad	86 %	-	95 %	84 %	-	99 %
Precision	87 %	-	95 %	84 %	-	-
F-score	91 %	-	91 %	95 %	-	-
#Imágenes-Val	624	500	200	624	112	624
Epoas	100	100	100	100	-	-

Finalmente, en el dataset de imágenes originales (sin procesar) se puede observar que las características extraídas son generales en la imagen, es decir,

el comportamiento del sistema clasifica neumonía tomando extrayendo características contenidas de las etiquetas, brazos y los bordes laterales de la imagen, regiones donde la neumonía no está presente fisiológicamente.

La comparación del desempeño entre diferentes sistemas CAD muestra que el sistema CAD propuesto es competitivo con los sistemas encontrados en la literatura. Jiang et al.[14] entrena, valida y prueba con 500 imágenes respectivamente, obteniendo una precisión del 92% con la arquitectura Xception, pero su estudio no sustenta qué características se toman en cuenta para llevar esta clasificación.

Sánchez et al.[23] propone generar un subespacio para entrenar la arquitectura Xception utilizando únicamente 400 imágenes para entrenamiento y 200 para prueba, obteniendo una exactitud del 96%, el mapa de calor mostrado toma características de la caja torácica y alrededores, además el algoritmo PCA reduce la información de una imagen.

Lujan et al.[17] empleó un esquema de transferencia de aprendizaje la cual resultó en una exactitud del 87%, pero al emplear el algoritmo Grad-CAM se puede ver que el sistema extrae características del área del corazón como significativas para clasificar una imagen en la clase de neumonía.

Varela et al [28,29] emplea una clasificación utilizando técnicas de tipo handcraft, los resultados presentan un sobre entrenamiento al obtener un ACC del 97% y 99% respectivamente, sin embargo, los autores no presentan las gráficas de Precisión/Perdida las cuales sirven para verificar el comportamiento de una red, además del uso de tres redes neuronales las cuales tendrán diferente comportamiento, a comparación de utilizar una la cual sea capaz de reconocer los diferentes conjuntos de patrones y así, poder entregar una sola clasificación al contrario de promediar el resultado de tres.

En este trabajo se propuso un método de procesamiento, el cual contribuye a la extracción de características de la caja torácica por parte de la arquitectura Xception, debido a que se obtiene la región de interés. Se logra una precisión del 91%. Para validar la eficiencia del sistema, se utilizó Grad-CAM, lo que confirma que utilizando las imágenes procesadas se pueden extraer características significativas del ROI, lo que resulta en un alto rendimiento de clasificación.




Fig. 8. Comparativa de los diferentes Grad-CAM obtenidos por A) Lujan[17], B) Sánchez[23], C) Sistema propuesto-imagen procesada, y D) Sistema propuesto-imagen original.

5. Conclusiones

El sistema CAD propuesto clasifica neumonía en imágenes de Rayos X, demuestra un buen desempeño en cuanto a las métricas de evaluación utilizadas: Exactitud, Especificidad y Sensibilidad, obteniendo 91 %, 91 %, 86 % respectivamente, garantizando la extracción de los patrones contenidos en la caja torácica y demostrando un desempeño similar en comparación con los sistemas CAD presentados en el estado del arte.

Nuestro trabajo futuro consistirá en utilizar arquitecturas CNN entrenadas desde cero (*from scratch*) para mejorar la clasificación perteneciente al área pulmonar, desarrollando un sistema multiclase donde se emplee la técnica de procesamiento propuesta.

Agradecimientos. Se le agradece cordialmente al Instituto Politécnico Nacional y al Consejo Nacional de Ciencia y Tecnología por el apoyo brindado para la realización de este proyecto.

Referencias

1. ACR-RSNA: Rayos X del Tórax (radiografía de tórax) (2019)
2. Bisong, E.: Google colaboratory. Building Machine Learning and Deep Learning Models on Google Cloud Platform. Apress, Berkeley, CA.
3. Buitinck, L., Louppe, G., Blondel, M., Pedregosa, F., et al.: Design for machine learning software: Experiences from the scikit-learn project (2013)
4. Características de las defunciones registradas en México (2020)
5. Caselles, V., Ron, K., Guillermo, S.: Geodesic active contours. In: Proceedings of IEEE international conference on computer vision. IEEE (1995)
6. Chollet, F.: Xception: Deep learning with depthwise separable convolutions. In: Proceedings of the IEEE conference on computer vision and pattern recognition (2017)
7. Ciregan, D., Ueli, M., Jürgen, S.: Multi-column deep neural networks for image classification. In: 2012 IEEE conference on computer vision and pattern recognition. IEEE (2012)
8. Cush, J. J.: Approach to articular and musculoskeletal disorders. Harrisons Principles Of Internal Medicine, vol. 2, pp. 1979–1986 (2001)
9. Das, A., Agrawal, H., Zitnick, L., Parikh, D., Batra, D.: Human attention in visual question answering: Do humans and deep networks look at the same regions?. Computer Vision and Image Understanding (2017)
10. WHO: Estimación Mundial de La Incidencia de Neumonía Clínica entre los menores de 5 años (2013)
11. Gonzalez, R. C., Richard, E. W.: Image processing. Digital Image Processing 2.1 (2007)
12. Goodfellow, I., Yoshua, B., Aaron, C.: Deep learning. MIT press, (2016)
13. He, K., Zhang, X., Ren, S., Sun, J.: Deep residual learning for image recognition (2015)
14. Jiang Z.: Chest x-ray pneumonia detection based on convolutional neural networks. In: 2020 International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE) pp. 341–344. IEEE (2020)

15. Kermany, D., Zhang, K., Goldbaum, M.: Labeled optical coherence tomography (OCT) and chest X-Ray images for classification (2018)
16. Krizhevsky, A., Ilya, S., Geoffrey, E. H.: Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, vol. 25 (2012)
17. Luján-García, J. E., et.al.: A transfer learning method for pneumonia. *Applied Sciences*, vol. 8, no. 2908, pp. 10 (2020)
18. Martín, A., Ashish, A., Paul, B., Eugene, B., Zhifeng, C., et.al.: TensorFlow: Large-scale machine learning on heterogeneous systems, software available from tensorflow.orgm (2015)
19. Mueller, J. P., Luca, M.: *Deep Learning for dummies* (2019)
20. Pizer, S. M., et al.: Adaptive histogram equalization and its variations. *Computer vision, graphics, and image processing* 39.3, pp. 355–368 (1987)
21. Reynolds, J. H., Arpan, K. B.: Imaging pneumonia in immunocompetent and immunocompromised individuals. *Current opinion in pulmonary medicine* 18.3, pp. 194–201 (2012)
22. Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A. et.al.: Imagenet large scale visual recognition challenge. *International Journal of Computer Vision*, vol. 115, no. 3, pp. 211–252 (2015)
23. Sanchez, K., et.al.: Subspace-based domain adaptation using similarity constraints for pneumonia diagnosis within a small chest x-ray image dataset. In: 2021 IEEE 18th International Symposium on Biomedical Imaging (ISBI) pp. 1232–1235 IEEE (2021)
24. Selvaraju, R. R., Das, A., Vedantam, R., Cogswell, M., Parikh, D., Batra, D.: Grad-Cam: why did you say that? visual explanations from deep networks via gradient-based localization (2016)
25. Sokolova, M., Guy, L.: A systematic analysis of performance measures for classification tasks. *Information processing & management*, vol. 45, no. 4, pp. 427–437 (2009)
26. Sons, J. W., Pitas, I.: *Digital image processing algorithms and applications* (2000)
27. Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R. Dropout: A simple way to prevent neural networks from overfitting. *The journal of machine learning research*. vol. 1929, no. 58 (2014)
28. Varela-Santos, S., Melin, P.: A new approach for classifying coronavirus COVID-19 based on its manifestation on chest x-rays using texture features and neural networks. *Information sciences*, vol. 545, pp. 403–14 (2021)
29. Varela-Santos, S., Melin, P.: A new modular neural network approach with fuzzy response integration for lung disease classification based on multiple objective feature optimization in chest Xray images, *Expert Systems with Applications* (2020)
30. Wang, H., Lei, Z., Zhang, X., Zhou, B., Peng, J.: *Machine learning basics*. Deep learning, pp. 98–164 (2016)
31. INSP: ¡El invierno se acerca! Y la neumonía lo sabe (2020)