

Redes Neuronales Convolucionales para la Detección de Neumonía

Mariano Cataldi ^[0009-0004-6267-5545], Marisa Panizzi ^[0000-0002-9699-1544],
Iris Sattolo ^[0000-0002-2132-0033]

Escuela Superior de Ingeniería, Informática y Ciencias Agroalimentarias Universidad de Morón. Cabildo 134 (B1708JPD), Partido de Morón, Argentina.

cataldi.mariano.19@gmail.com, marisapanizzi@outlook.com, iris.sattolo@gmail.com

Resumen. El reconocimiento de imágenes por computadora puede aplicarse en diversos ámbitos, tal es el caso de la medicina donde la interpretación de placas radiográficas o tomografías computarizadas, nos permite realizar diagnóstico. En este trabajo se presenta un mapeo sistemático de la literatura (en inglés, systematic mapping study o SMS) con el propósito de identificar el estado del arte y descubrir las contribuciones que existen con relación al análisis y reconocimiento de imágenes para diagnósticos de neumonía y otras enfermedades. Se realizó una búsqueda en diversas librerías digitales desde enero del año 2011 a octubre del año 2023. De un total de 106 artículos encontrados, se analizaron 14 estudios primarios. Se evidenció que el reconocimiento de imágenes puede emplearse en distintos tipos de patologías, que en el 85% de los artículos utilizaron redes neuronales convolucionales, en el 75% emplearon arquitecturas de redes neuronales convolucionales pre armadas y en solo el 25% redes de elaboración propia. La fuente de obtención de datos es variada, aunque predominan los Data Sets como Kaggle.

Keywords: clasificación de imágenes, detección de neumonía, redes neuronales convolucionales, mapeo sistemático de la literatura.

1. Introducción

La neumonía es una enfermedad respiratoria responsable de más de 4 millones de muertes en al año en todo el mundo [1]. La misma es producida por una infección de origen viral, bacterial, fúngica o de otros microorganismos [2] donde los sacos aéreos de los pulmones se llenan de líquido o pus producto de la infección, produciendo dificultades para respirar siendo en casos de adultos mayores de 65 años o niños menores de 5 es sumamente peligrosa y letal [3]. La neumonía se diagnostica a través del análisis de una radiografía de tórax, en caso de haber una inflamación estamos ante la presencia de neumonía [4]. Además, el diagnóstico puede ser reforzado con un análisis de sangre para controlar que el sistema inmunitario está combatiendo la infección [5]. En esta investigación nos enfocaremos en recopilar información de interés que nos permita llegar a la elaboración de un modelo de redes neuronales convolucionales que nos posibilite determinar si un paciente presenta o no neumonía a través del estudio de una placa de tórax. Dentro del campo de la IA se pueden utilizar técnicas como las redes neuronales convolucionales, las cuales tienen como función analizar y clasificar imágenes con el fin de poder descubrir patrones en las mismas, lo cual permitirían desarrollar un software que pueda analizar placas y en base al entrenamiento realizado poder detectar pulmones infectados con neumonía.

Como paso previo al entrenamiento de un modelo de red neuronal que realice la detección de neumonía se realiza un mapeo sistemático de la literatura o SMS, con el fin de analizar el estado del arte y recopilar literatura de investigaciones realizadas en el tema previamente. Para realizar el SMS se siguieron los lineamientos planteados por Kitchenham *et al.* [6] y Petersen *et al.* [7].

El artículo se estructura de la siguiente manera: en la Sección 2 se describe la planificación del SMS, en la Sección 3 se describe su ejecución y los resultados del SMS. y, finalmente, en la Sección 4 se exponen las conclusiones y trabajos futuros.

2. Planificación del SMS

En esta sección se presenta la definición de los elementos del protocolo del SMS: las preguntas de investigación (PI) la estrategia de búsqueda, los criterios y el proceso de selección de los estudios primarios la estrategia de extracción de datos y por último el proceso de síntesis de datos.

El objetivo de este SMS es responder la siguiente pregunta de investigación (PI):
¿Es posible desarrollar un modelo de software que diagnostique neumonía realizando un análisis de imágenes de radiografías de tórax?

Esta pregunta principal se descompone en un conjunto de sub-preguntas (PI1-8), las cuales se presentan a continuación:

- *PI1: ¿Qué contribuciones existen respecto al reconocimiento de imágenes médicas con machine learning?*
- *PI2: ¿Qué métodos se utilizan en los análisis y reconocimiento de imágenes?*
- *PI3: ¿Qué Arquitecturas de Redes Neuronales convolucionales son las más utilizadas?*
- *PI4: ¿Cuántas capas utilizan las redes neuronales convolucionales?*
- *PI5: ¿Qué tipo de imágenes se utilizan?*
- *PI6: ¿Qué fuente de datos utilizan los autores de los trabajos seleccionados?*
- *PI7: ¿Qué tipo de investigación se presenta en los artículos?*

Se decide realizar la búsqueda en las siguientes bibliotecas y repositorios digitales: *IEEE Xplore*, *Springer* y *ScienceDirect* considerando publicaciones de congresos y revistas. La búsqueda se realizó en un período comprendido entre enero del 2011 a octubre del 2023. La cadena de búsqueda utilizada es:

(“Machine Learning” AND “Image Analysis”) or (“Machine Learning” AND “Chest Image Analysis”) OR (“Pneumonia Detection Image” AND (“Image Analysis” OR “Machine Learning”))

Los criterios de inclusión y exclusión utilizados para el proceso de selección de artículos se presentan en la Tabla 1.

Para dar respuesta a cada una de las preguntas de investigación (PI) se definió un esquema de clasificación, que por restricciones de espacio se presenta en un apéndice en [10], junto con el formulario de extracción de datos. Se utiliza una síntesis temática basada en el esquema de clasificación.

El proceso de selección de los estudios consistió en los siguientes pasos: 1) realizar la búsqueda en las fuentes definidas aplicando la cadena en el título y/o en el resumen, 2) eliminar los artículos duplicados, 3) aplicar los criterios de inclusión y exclusión en el título, resumen y palabras clave, 4) aplicar los criterios de inclusión y exclusión al texto completo. Este proceso permitió la selección de los estudios primarios que se analizaron para dar respuesta a las preguntas de investigación (PI) formuladas.

Tabla 1. Criterios de inclusión y exclusión.

Criterios de inclusión	Criterios de exclusión
Artículos que contengan los términos de búsqueda en el título, palabras clave, resumen, o introducción.	Artículos a los cuales no se tenga acceso.
Artículos en idioma inglés y español.	Artículos que solamente hagan mención a trabajos o investigaciones en curso (generalmente, artículos menores a 5 páginas).
Artículos duplicados: si hay varios artículos de un mismo autor que contemple la misma investigación, se considerará el más completo y el más reciente.	Artículos que no coincidan con los criterios de inclusión.
Artículos que contengan cadenas candidatas en el título, palabras clave y/o en el resumen.	Literatura gris, tesis doctorales, presentaciones en PowerPoint.
Artículos publicados en congresos o revistas con revisión por pares.	

3. Ejecución y resultados del SMS.

Por restricciones de espacio, la cantidad de artículos encontrados en cada uno de las librerías, plataformas y repositorios digitales definidos en el protocolo de revisión se encuentran en un apéndice en [10] junto con el listado de los 14 estudios primarios analizados.

A continuación, se pretende dar respuesta a las preguntas de investigación (PI):

PI1: ¿Qué contribuciones existen respecto al reconocimiento de imágenes con machine learning?

En la lectura de los artículos se encontraron 14 modelos basados en el reconocimiento de imágenes con machine learning. En los mismos se abordaron distintas patologías médicas. Seis de ellos se basaron en la detección de neumonía, cinco en COVID-19, tres con nódulos pulmonares, en uno se detalló un modelo para analizar distintos tipos de lesiones (lesiones hepáticas, lesiones óseas, ganglios linfáticos inflamados, etc.), uno de los modelos trató sobre el análisis de imágenes de anomalías cerebrales y el último sobre distintas muestras de tejidos. Cabe aclarar también que en dos artículos se abordaron COVID-19 y neumonía en conjunto y en otro lesiones varias y nódulos pulmonares.

PI2: ¿Qué métodos se utilizan en el análisis y reconocimiento de imágenes?

En 12 de los artículos seleccionados se utilizaron redes neuronales convolucionales como método para el análisis y reconocimiento de imágenes, en un solo artículo se usó una red neuronal y en otro no se utilizaron redes neuronales de ningún tipo en su lugar se emplearon otros algoritmos de Machine Learning y Deep learning. En cinco de los doce artículos que trabajan con redes neuronales convolucionales se complementaron con algoritmos de Deep Learning, en otros 4, se adicionaron algoritmos de machine learning además de basar su modelo en redes neuronales convolucionales.

PI3: ¿Qué Arquitecturas de Redes Neuronales convolucionales son las más utilizadas?

Las arquitecturas más utilizadas fueron GoogLeNet, DenseNet-121, AlexNet y las propias desarrolladas por los autores de los artículos. En cinco de los doce artículos que utilizaron redes neuronales convolucionales implementaron 3 arquitecturas distintas, en 6 artículos implementaron una sola arquitectura y en uno solo 4 arquitecturas distintas. Cabe aclarar que en dos artículos no se utilizaron redes neuronales convolucionales.

PI4: ¿Cuántas capas poseen las redes neuronales convolucionales de los modelos propuestos?

Las cantidades de capas por cada arquitectura es variable, cada una de las arquitecturas presenta un número de capas diferente, AlexNet 8, CifarNet 10, DenseNet 121 y 50 respectivamente, GoogLeNet 22, InceptionV3 48, EP-10 Propia 12, EP-14 Propia 3, ResNet 18 y 50 respectivamente, SqueezeNet 18, U-NET 23, y VGG 16 y 19 respectivamente.

PI5: ¿Qué tipo de imágenes se utilizan?

En once de los artículos, el tipo de imagen utilizada fueron las radiografías de tórax, en los artículos restantes se utilizaron imágenes de tomografías de ganglios linfáticos, muestras de tejidos, tomografías cerebrales, tomografías y radiografías de distinto tipo de lesiones. Como eje central de investigación se buscaron estudios basados en neumonía y análisis de radiografías de tórax, sin embargo, para enriquecer la literatura y tener una base teórica más amplia en algoritmos y diseños de redes neuronales convolucionales, se seleccionaron algunos artículos que realizaron un reconocimiento y análisis de imágenes médicas más amplio como analizar y detectar varios tipos de lesiones o reconocer imágenes de distintos tipos de tejidos.

PI6: ¿Qué fuente de datos utilizan los autores de los trabajos seleccionados?

En siete de los catorce artículos analizados se utilizó un data set, el más utilizado fue kaggle [8]. El otro data set utilizado fue DeepLesion. En los demás artículos, las imágenes se obtuvieron de cuatro hospitales, dos de escuelas de medicina y de un laboratorio.

PI7: ¿Qué tipo de investigación se presenta en los artículos?

De los artículos analizados, dos pertenecen a la categoría de evaluación, cinco a propuestas de solución y siete a validaciones.

4. Conclusiones y trabajos futuros.

Los resultados obtenidos del SMS, permitieron la construcción del estado del arte respecto a los aportes existentes sobre análisis y reconocimiento de imágenes para la detección de neumonía y otras patologías.

En cuanto a las respuestas a las preguntas de investigación se pudo evidenciar que se pueden elaborar modelos en una amplia variedad de patologías, como a su vez desarrollar modelos que trabajen con distintos tipos de imágenes en un solo sistema. Se logró demostrar que no es del todo necesario desarrollar una red neuronal convolucional desde cero, ya que pueden adaptarse redes ya desarrolladas y probadas para ese fin. Además, se pueden utilizar otro tipo de algoritmos basados en machine learning para analizar y reconocer imágenes. Los sets de datos para entrenar redes neuronales están al alcance de cualquier desarrollador en repositorios de internet, obteniendo información confiable, abundante y gratuita.

Como trabajos futuros se podrían entrenar modelos de redes neuronales convolucionales, que además de reconocer imágenes, pueda analizar otro tipo de datos de entrada para crear un sistema experto que realice diagnósticos más complejos que no puede ser realizados únicamente con el análisis y detección de patrones en imágenes.

Referencias

1. Y.Li, Z. Zhang , C. Dai, Q.Dong , S.Badrigilan. Accuracy of Deep learning for automated detection of pneumonia using chest X-Ray images: A systematic review and meta-analysis. *Comput Biol Med*, 2020.
2. P. Szepesi, L. Szilágyi. Detection of pneumonia using convolutional neural networks and deep learning. *ScienceDirect*, 2022.
3. Wang H, Jia H, Lu L, Xia Y. Thorax-Net: an attention regularized deep neural network for classification of thoracic diseases on chest radiography. *IEEE J Biomed Health Inform.*,2020.
4. H. Bhatt, M. Shah, A Convolutional Neural Network ensemble model for Pneumonia Detection using chest X-ray images, *ScienceDirect*, 2023.
5. D. Wootton, C. Feldman, The diagnosis of pneumonia requires a chest radiograph (X-ray) yes, no or sometimes? *Pneumonia* 5, Biomedcentral, 2014.
6. B. Kitchenham, D. Budgen y P. Brereton, *Evidence-Based Software Engineering and Systematic Reviews*, USA: CRC Press, 2015.
7. K. Petersen, R. Feldt, S. Mujtaba y M. Mattsson, Systematic mapping studies in software engineering, In: *Proceedings of the 12th International Conference on Evaluation and Assessment in Software Engineering*, 2008.
8. <https://www.kaggle.com/>
9. R.Wieringa., N.Maiden., N.Mead., C.Rolland. Requirements engineering paper classification and evaluation criteria: a proposal and a discussion. *Requirements Engineering*, 11(1), pp. 102-107, 2006.
10. Cataldi Mariano. Apendice- Redes Neuronales Convolucionales para la Detección de Neumonía. Disponible en: <https://doi.org/10.6084/m9.figshare.26035963>, 2024.