

Deep learning para el procesamiento de imágenes de neumotórax a través de técnicas de visión computacional

Deep learning for pneumothorax image processing through computer vision techniques

✉ Maquera, Henry G.¹; Delgado, Marjorie G.²; Aguilar, Miguel E.¹ y Huaroc, Jhonny Á.¹

¹ Ingeniería de Sistemas, Universidad Nacional del Centro, Huancayo, Perú.

² Escuela de Posgrado Newmann, Tacna, Perú.

Resumen: La inteligencia artificial viene participando en diversas áreas de desarrollo social. Uno de los ámbitos de acción es el área médica a través de una red neuronal convolucional (CNN) que permite un soporte matemático de procesamiento en forma de cuadrícula en imágenes. Los patrones y características de 197 imágenes categorizadas en: 120 casos benignos, 561 casos malignos y 416 casos normales fueron procesadas. Los mecanismos de la red convolucional se basaron en operaciones matriciales que identifican las características relevantes para las diversas imágenes alimentadas en la red neuronal. El análisis de los resultados logró una precisión de 73.12% de validación con datos de entrenamiento y un 60.27% de precisión con datos de validación para diagnosticar enfermedades y tumores en los pulmones. Este nivel de precisión establece como consecuencia que se deben realizar mayores estudios con el fin de elevar los grados de precisión ya que podría generarse errores en los diagnósticos.

Palabras clave: Inteligencia artificial, CNN, red neuronal, enfermedad pulmonar..

Abstract: Artificial intelligence has been participating in various areas of social development. One of the areas of action is the medical area through a convolutional neural network (CNN) that allows a mathematical support of processing in the form of a grid in images. The patterns and characteristics of 197 images categorized into: 120 benign cases, 561 malignant cases and 416 normal cases were processed. The convolutional network mechanisms were based on matrix operations that identify the relevant features for the various images fed into the neural network. Analysis of the results achieved 73.12% validation accuracy with training data and 60.27% accuracy with validation data for diagnosing lung diseases and tumors. This level of accuracy establishes as a consequence that further studies should be carried out in order to raise the degrees of accuracy as it could generate errors in the diagnoses.

Keywords: Artificial intelligence, CNN, neural network, lung disease..



Referencia: Maquera, H. G., Delgado, M. G., Aguilar, M. E., y Huaroc, J. Á. (2024). Deep learning para el procesamiento de imágenes de neumotórax a través de técnicas de visión computacional. *Prospectiva Universitaria*, 21(02), 27–30. <https://revistas.uncp.edu.pe/index.php/prospectiva/article/view/2218>

Recibido: 14 de octubre 2024

Aceptado: 25 de junio 2024

Publicado: 30 de junio 2024

Prospectiva Universitaria. Vol. 21, núm. 02, julio a diciembre, 2024. Esta obra está bajo una licencia de Creative Commons



CC BY 4.0 DEED

Attribution 4.0 International
<https://creativecommons.org/licenses/by/4.0/>

1. Introducción

Las técnicas de inteligencia artificial vienen aportando muchos instrumentos para detectar diversos tipos de males a través de la detección de imágenes que han sido previamente tratadas mediante el etiquetado (Jin et al., 2023). Por lo que el reconocimiento de imágenes suele proporcionar información para lograr la detección de diversos tipos de patologías (Seah et al., 2021). Una patología que viene apareciendo frecuentemente es el cáncer, por lo que una exploración de imágenes como una radiografía sirven para diagnosticar neumonía, tumores pulmonares y anomalías anatómicas (Sharma & Aljani, 2022). La radiografía de tórax se ha convertido en una evaluación de imagen médica muy utilizada puesto que permite un diagnóstico de patologías cardíacas, traumatismos torácicos y tipos de neoplasia maligna (Kaur & Mittal, 2022).

Debe tenerse presente que el uso de imágenes de radiografías de tórax experimenta algunas limitaciones sobre todo en el análisis bidimensional de la imagen de los rayos X donde se podrían presentar altos índices de error. El alto grado de error en diagnósticos se deben al cansancio de los médicos y a la inexperiencia en la lectura de las imágenes de radiografía (Y. Wang et al., 2021). Por lo que este problema que vienen afectando en la atención al paciente se resumen en: la carga de trabajo al personal médico, y a la subjetividad en la interpretación de pruebas de radiografía (Liz et al., 2023).

Las imágenes de radiografía de tórax presentan características adecuadas para un análisis con redes neuronales convolucionales (CNN) donde la participación de algoritmos de inteligencia artificial y los conocimientos médicos pueden mejorar los diagnósticos de las dolencias de los pacientes, al mismo tiempo que el tiempo requerido para identificar un diagnóstico se podría reducir significativamente con un nivel de precisión adecuada (H. Wang & Xia, 2023). El registro de las imágenes de radiografía permite al personal médico realizar comparaciones, y mejorar la precisión de los diagnósticos al paciente. El registro de imágenes de los pulmones es una actividad muy importante para la detección oportuna de males en la salud (Xiao et al., 2023).

El uso de redes neuronales convolucionales tiene como fundamento la comunicación entre las neuronas del cerebro. Inicialmente se realiza un filtro de los datos para eliminar el efecto del ruido de la información, seguidamente se detectan los picos neuronales a partir de la información acumulada. El algoritmo de redes neuronales convolucionales (CNN) multicapa permite evaluar características y estructuras para mejorar

la exactitud de la clasificación por lo que se considera un adecuado método para la evaluación de tumores en los pulmones (Zhang & Li, 2023).

Esta investigación realiza un aprendizaje profundo a través de una red convolucional para detectar tumores malignos de cáncer en los pulmones de los pacientes. La red neuronal convolucional (CNN) tiene la capacidad de lograr procesar características a partir de datos de imágenes en 2D. La investigación se basa en el procesamiento de las características de las imágenes de pulmones asignadas con las etiquetas de entrenamiento, validación y prueba.

El clasificador CNN permite una evaluación supervisada donde se cuenta con un mapa de características y se logra una salida de probabilidad que corresponda con la presencia de una enfermedad tumoral de cáncer. La CNN está compuesta por una transformación oculta $h()$ compuesta por bloques convolucionales que se encarga de procesar el mapa de características X en otro esquema de características H que se utilizó para la clasificación final. Los bloques convolucionales contienen una capa 1D convolucional, una capa de activación ReLU() y una capa de transformación max pooling para reducir la dimensionalidad (Lin et al., 2023).

2. Materiales y métodos

Para el diseño y construcción de la red neuronal convolucional se consideró una arquitectura que estructuró la organización de capas y componentes para la clasificación de imágenes (M. Wang et al., 2023). Para la arquitectura de la red de neuronal se consideró una estructura secuencial compuesta por capas convolucionales para la extracción de características mediante patrones y bordes, capas de activación con función ReLU para el aprendizaje de rasgos complejos, capas de agrupación para reducir la dimensionalidad, capas conectadas para la clasificación final y una capa de salida que mapea las probabilidades sobre las imágenes procesadas.

2.1. Arquitectura de red neuronal convolucional

El proceso de construcción de la red neuronal CNN se basó en los principios de convolución en la que una operación que toma como entrada dos imágenes y genera una tercera. La idea principal de esta red neuronal es la de encontrar los pesos y los núcleos de convolución que minimizan el error en la clasificación mediante una operación que implica movilizar un núcleo sobre una matriz de datos y realizar el cálculo de valores escalares.

2.2. Organización de los datos de estudio

Las imágenes de estudio se catalogaron de acuerdo a la siguiente distribución: se contó con 197 archivos para casos de prueba, mientras que para los diagnósticos de cáncer de pulmón se procesaron 120 imágenes de casos benignos, 561 imágenes de casos malignos y 416 imágenes de casos normales.

3. Resultados

El análisis de información inicial confirmó la clasificación adecuada de los tipos de etiquetado con que se contaba para el estudio de las imágenes, categorizadas bajo los agrupamientos de casos benignos, casos malignos y casos normales. La información proporcionada por la red neuronal permitió establecer el modelo secuencial de la red CNN para el tratamiento de la información.

El tratamiento de la información permitió evaluar la precisión del modelo sobre la cantidad de épocas o veces que un modelo atraviesa la totalidad de los datos durante el entrenamiento, parámetro vital para equilibrar el bajo rendimiento y el sobre ajuste. Durante el entrenamiento se realizó la medición de la métrica loss que permitió la comparación de los valores calculados en relación a los valores reales. Los valores de pérdida se estabilizaron en 0.6960 mientras que el accuracy se elevó a 0.7312, estableciendo un comportamiento de predicciones correctas sobre los datos reales.

El modelo fue evaluado con la métrica de validación de pérdida (val_loss) obteniendo un valor de 1.0586. Por su parte, la métrica de precisión de validación (val_accuracy) logró un valor de 0.6027, indicando que el 60.27% de las predicciones logradas durante la validación fueron correctas. Estos resultados reflejan que el modelo está aprendiendo el patrón de datos de entrenamiento para su posterior generalización. Asimismo, las precisiones de prueba y pérdida permiten evaluar el comportamiento de la red neuronal y controlar el sobreajuste (overfitting) en los datos de entrenamiento.

4. Discusión

El estudio realizado por Yang et al. (2023) analizó características como tamaño de la lesión, localización de la lesión, profundidad de la punción y la posición, fomentando el tamaño de la lesión como factor muy importante ya que las lesiones pequeñas suelen difi-

cultar el uso de instrumentos médicos. Esta investigación, en cambio, se orienta al análisis de características de imagen como principal factor de precisión. Por otro lado, Belletti et al. (2021) establece que la falta de un protocolo específico podría causar la omisión de algunos casos, aunque no serían clínicamente relevantes; de igual manera, nuestra investigación se basó en el análisis de imágenes de rayos X mediante redes neuronales CNN para lograr un diagnóstico adecuado. Bhandari et al. (2022) formuló que los parámetros tradicionales de validación muestran la pérdida del modelo y la exactitud con curvas de buen ajuste, alcanzando porcentajes de precisión de entrenamiento de 95,76 ± 1,15 y de validación de 94,54 ± 1,33. De forma similar, esta investigación logró una precisión media de entrenamiento de 73.12 ± 0.69 y de validación de 60.27 ± 1.0586 en los 18 pliegues del conjunto de datos. Agrawal y Choudhary (2023) realizaron una comparación de modelos ligeros (ALCNN) donde el modelo tCheXNet obtuvo un área bajo la curva de 0,708 frente al 0,79 del modelo propuesto; paralelamente, esta investigación desarrollada mediante redes CNN permite lograr un 60.27% de eficiencia en la formulación de diagnósticos.

5. Conclusiones

El uso de imágenes para iniciar el tratamiento de datos mediante una red neuronal convolucional para diagnosticar dolencias tumorales en los pulmones permite formular un rápido y confiable diagnóstico. La red neuronal CNN basada en el procesamiento de imágenes es un mecanismo de atención para la identificación de características bajo un modelo matemático que brinda soporte en la recalibración de características y el aumento de datos para evitar el sobreajuste, por lo que se recomienda la exploración de modelos más eficientes para elevar los índices de detección.

Un modelo de red neuronal CNN permite un adecuado tratamiento de imágenes de rayos X de pulmones con el fin de detectar tumores malignos. Los índices de validación del 73.12% y del 60.27% fomentan que los modelos de imágenes deben ser investigados con el fin de mejorar los índices de diagnóstico, puesto que las imprecisiones podrían generar diagnósticos erróneos que perjudican directamente la salud del paciente.

Referencias

- Belletti, A., Palumbo, D., Zangrillo, A., Fominskiy, E. V., Franchini, S., Dell'Acqua, A., Marinosci, A., Monti, G., Vitali, G., Colombo, S., Guazzarotti, G., Lembo, R., Maimeri, N., Faustini, C., Pennella, R., Mushaq, J., Landoni, G., Scandroglio, A. M., Dagna, L., & De Cobelli, F. (2021). Predictors of Pneumothorax/Pneumomediastinum in Mechanically Ventilated COVID-19 Patients. *Journal of Cardiothoracic and Vascular Anesthesia*, 35(12), 3642-3651. <https://doi.org/10.1053/j.jvca.2021.02.008>

- Bhandari, M., Shahi, T. B., Siku, B., & Neupane, A. (2022). Explanatory classification of CXR images into COVID-19, Pneumonia and Tuberculosis using deep learning and XAI. *Computers in Biology and Medicine*, 150, 106156. <https://doi.org/10.1016/j.combiomed.2022.106156>
- Jin, Y., Lu, H., Zhu, W., & Huo, W. (2023). Deep learning based classification of multi-label chest X-ray images via dual-weighted metric loss. *Computers in Biology and Medicine*, 157, 106683. <https://doi.org/10.1016/j.combiomed.2023.106683>
- Kaur, N., & Mittal, A. (2022). RadioBERT: A deep learning-based system for medical report generation from chest X-ray images using contextual embeddings. *Journal of Biomedical Informatics*, 135, 104220. <https://doi.org/10.1016/j.jbi.2022.104220>
- Lin, Z.-w., Dai, W.-l., Lai, Q.-Q., & Wu, H. (2023). Deep learning-based computed tomography applied to the diagnosis of rib fractures. *Journal of Radiation Research and Applied Sciences*, 16(2), 100558. <https://doi.org/10.1016/j.jrras.2023.100558>
- Liz, H., Huertas-Tato, J., Sánchez-Montaños, M., Del Ser, J., & Camacho, D. (2023). Deep learning for understanding multilabel imbalanced Chest X-ray datasets. *Future Generation Computer Systems*, 144, 291-306. <https://doi.org/10.1016/j.future.2023.03.005>
- Seah, J. C. Y., Tang, C. H. M., Buchlak, Q. D., Holt, X. G., Wardman, J. B., Aimoldin, A., Esmaili, N., Ahmad, H., Pham, H., Lambert, J. F., Hachey, B., Hogg, S. J. F., Johnston, B. P., Bennett, C., Oakden-Rayner, L., Brotchie, P., & Jones, C. M. (2021). Effect of a comprehensive deep-learning model on the accuracy of chest x-ray interpretation by radiologists: A retrospective, multireader multicase study. *The Lancet Digital Health*, 3(8), e496-e506. [https://doi.org/10.1016/S2589-7500\(21\)00106-0](https://doi.org/10.1016/S2589-7500(21)00106-0)
- Sharma, S., & Alijani, A. (2022). Insertion of chest drain for pneumothorax. *Anaesthesia & Intensive Care Medicine*, 23(3), 172-176. <https://doi.org/10.1016/j.mpac.2021.12.002>
- Wang, H., & Xia, Y. (2023). Domain-ensemble learning with cross-domain mixup for thoracic disease classification in unseen domains. *Biomedical Signal Processing and Control*, 81, 104488. <https://doi.org/10.1016/j.bspc.2022.104488>
- Wang, M., Zhang, L., Yu, H., Chen, S., Zhang, X., Zhang, Y., & Gao, D. (2023). A deep learning network based on CNN and sliding window LSTM for spike sorting. *Computers in Biology and Medicine*, 159, 106879. <https://doi.org/10.1016/j.combiomed.2023.106879>
- Wang, Y., Wu, J., Lv, M., Shao, Z., Hungwe, M., Wang, J., Bai, X., Xie, J., Wang, Y., & Geng, W. (2021). Metabolism Characteristics of Lactic Acid Bacteria and the Expanding Applications in Food Industry. *Frontiers in Bioengineering and Biotechnology*, 9. <https://doi.org/10.3389/fbioe.2021.612285>
448 citations (Crossref/DOI) [2025-07-07].
- Xiao, H., Xue, X., Zhu, M., Jiang, X., Xia, Q., Chen, K., Li, H., Long, L., & Peng, K. (2023). Deep learning-based lung image registration: A review. *Computers in Biology and Medicine*, 165, 107434. <https://doi.org/10.1016/j.combiomed.2023.107434>
- Yang, S., Lou, L., Wang, W., Li, J., Jin, X., Wang, S., Cai, J., Kuang, F., Liu, L., Hadjouni, M., Elmannai, H., & Cai, C. (2023). Pneumothorax prediction using a foraging and hunting based ant colony optimizer assisted support vector machine. *Computers in Biology and Medicine*, 161, 106948. <https://doi.org/10.1016/j.combiomed.2023.106948>
- Zhang, J., & Li, K. (2023). A multi-view CNN encoding for motor imagery EEG signals. *Biomedical Signal Processing and Control*, 85, 105063. <https://doi.org/10.1016/j.bspc.2023.105063>