

Algoritmos de Inteligencia Artificial para la Detección de Patologías Relacionadas con el Cáncer de Pulmón a través del Análisis de Imágenes utilizando Redes Neuronales Convolucionales y Data Augmentation: un mapeo sistemático de la literatura

Mg. Ing. Pablo Ramirez Amador

Universidad Abierta Interamericana. Facultad de Tecnología informática.
Centro de Altos Estudios en Tecnología Informática. Buenos Aires, Argentina.

Pablo.RamirezAmador@alumnos.uai.edu.ar

Abstract.

El cáncer de pulmón es una de las principales causas de muerte en el mundo y su diagnóstico temprano es crucial para mejorar el pronóstico y la calidad de vida de los pacientes. Sin embargo, el proceso de interpretación de imágenes médicas para la detección del cáncer de pulmón es complejo y requiere de expertos capacitados. En este **contexto**, la inteligencia artificial (IA) y el aprendizaje profundo (DL) surgen como herramientas potenciales para automatizar y optimizar el análisis de imágenes. El **objetivo** de este trabajo es revisar las aplicaciones más recientes y relevantes de la IA y el DL en el campo de la radiología para la detección del cáncer de pulmón. Para ello, se realizó una búsqueda exhaustiva en bases de datos científicas como PubMed, IEEEEXPLORE, Scopus y Web of Science y se seleccionaron 96 artículos publicados desde el año 2015 hasta la actualidad que abordan el uso de IA y DL en la ingeniería biomédica. Se enfatiza el uso de redes neuronales convolucionales (CNN) con transferencia de conocimiento y Data Augmentation como **técnicas** prometedoras para mejorar la precisión y la eficiencia del proceso de interpretación de imágenes. Los **resultados** muestran que el uso de IA y DL puede ofrecer una alternativa efectiva para el diagnóstico temprano del cáncer de pulmón, con una alta sensibilidad y especificidad. Sin embargo, también se identifican limitaciones y desafíos actuales que deben abordarse para garantizar su aplicación responsable y segura en la práctica clínica, tales como la falta de datos estandarizados, la explicabilidad de los modelos, la privacidad de los pacientes y las implicaciones éticas y sociales. Se **concluye** que el uso de IA y DL puede tener un impacto positivo en la atención al paciente con cáncer de pulmón, pero se requiere más investigación y regulación para asegurar su calidad y confiabilidad.

Keywords: Inteligencia Artificial, Aprendizaje Profundo, Redes Neuronales Convolucionales, Radiología, Cáncer de Pulmón.

Introducción

El cáncer de pulmón es una enfermedad que representa una gran amenaza para la salud pública y cuya tasa de supervivencia es baja (Chaunzwa et al., 2021). Existen dos tipos principales de cáncer de pulmón: el cáncer de pulmón de células no pequeñas (NSCLC) y el cáncer de pulmón de células pequeñas (SCLC). El NSCLC es el más común y se caracteriza por un crecimiento lento y una baja respuesta a la quimioterapia. El diagnóstico temprano es crucial para mejorar la probabilidad de supervivencia del paciente (Shimazaki et al., 2022).

Una de las técnicas más utilizadas para la detección del cáncer de pulmón es la tomografía computarizada (TC), que consiste en obtener imágenes tridimensionales del tórax mediante rayos X. La TC permite visualizar con detalle las estructuras pulmonares y detectar posibles anomalías, como nódulos o masas. Sin embargo, la interpretación de las imágenes médicas es un proceso complejo y que a menudo requiere de la ayuda de expertos altamente capacitados, lo que puede limitar la disponibilidad y accesibilidad a este tipo de diagnóstico (Kalaivani et al., 2020).

En este contexto, el uso de la inteligencia artificial (IA) puede ofrecer una alternativa efectiva para el análisis automatizado y el diagnóstico temprano de cáncer de pulmón a partir de imágenes médicas. En particular, las redes neuronales (NN) son modelos computacionales inspirados en el funcionamiento del cerebro humano, capaces de aprender a partir de datos y realizar tareas complejas, como la clasificación o la segmentación de imágenes. Una red neuronal convolucional (CNN) es un tipo especial de NN que se adapta especialmente bien al procesamiento de imágenes, ya que utiliza filtros que extraen características relevantes de los píxeles (Wang, 2022).

En este trabajo, proponemos el uso de una CNN pre-entrenada para la detección del NSCLC a partir de imágenes de TC. Una CNN pre-entrenada es una NN que ya ha sido entrenada con un gran conjunto de datos genéricos, como ImageNet, y que se puede reutilizar para una tarea específica mediante la transferencia de conocimiento. Algunos ejemplos de CNN pre-entrenadas son VGG16 o ResNet, que han demostrado un alto rendimiento en diversas aplicaciones (Wang, 2022). Para adaptar la CNN pre-entrenada a nuestro problema, aplicamos Data Augmentation, que consiste en generar nuevas imágenes a partir de las originales mediante transformaciones como rotación, escala o ruido. De esta forma, aumentamos la cantidad y la variedad de datos disponibles para el entrenamiento y reducimos el riesgo de sobreajuste (Wang, 2022).

Los resultados esperados de nuestro trabajo son los siguientes: (1) demostrar la viabilidad y la eficiencia de usar una CNN pre-entrenada para la detección del NSCLC; (2) comparar el rendimiento de diferentes CNN pre-entrenadas y seleccionar la más adecuada para nuestro problema; (3) evaluar la influencia del Data Augmentation en la precisión y la robustez de la CNN; y (4) contribuir al avance del conocimiento en el campo de la ingeniería biomédica y la salud pública. Algunas limitaciones o desafíos

que enfrentamos son: (1) obtener un conjunto de datos suficientemente grande y representativo de imágenes de TC con etiquetas confiables; (2) garantizar la privacidad y la seguridad de los datos médicos; y (3) validar los resultados con expertos clínicos.

2. Preguntas de investigación

Uno de los puntos más importantes de un mapeo sistemático es la lectura crítica del material seleccionado. Este análisis está direccionado por las siguientes preguntas de investigación:

Tabla 1. Preguntas guía del mapeo

PREGUNTAS DE INVESTIGACIÓN	MOTIVACIÓN
P1. ¿Qué tipo de red neuronal convolucional es la más adecuada para el análisis de imágenes médicas para la detección del cáncer de pulmón?	M1. Determinar cuál es el modelo de inteligencia artificial que ofrece el mejor rendimiento y la mayor precisión para el diagnóstico temprano del cáncer de pulmón a partir de imágenes de tomografía computarizada.
P2. ¿Qué beneficios tiene el uso de Data Augmentation en comparación con otras técnicas para aumentar la cantidad y la variedad de datos disponibles para el entrenamiento de la red neuronal convolucional?	M2. Identificar las ventajas y desventajas de diferentes métodos para generar más datos de entrenamiento y mejorar la robustez del modelo ante variaciones en las imágenes de prueba.
P3. ¿Qué desafíos y limitaciones se presentan en la aplicación de la inteligencia artificial para el diagnóstico del cáncer de pulmón en la práctica clínica?	M3. Identificar los obstáculos y las barreras que dificultan el uso efectivo y responsable de la inteligencia artificial para el diagnóstico del cáncer de pulmón en el contexto real de la atención médica.

3. Métodos de revisión

Para realizar esta revisión, se siguió el protocolo de mapeo sistemático propuesto por Petersen et al. (2008), que consiste en cinco pasos: definir las preguntas de investigación, realizar la búsqueda de estudios, aplicar los criterios de inclusión y exclusión, extraer y clasificar los datos y presentar los resultados.

3.1. Fuentes

Se utilizó la herramienta search_web para buscar artículos científicos publicados desde el año 2015 hasta la actualidad que aborden el uso de la inteligencia artificial y el aprendizaje profundo en el análisis de imágenes médicas para la detección del cáncer de pulmón. La búsqueda se realizó en bases de datos científicas como PubMed,

IEEEEXPLORE, Scopus y Web of Science, usando las siguientes palabras clave: “inteligencia artificial”, “aprendizaje profundo”, “redes neuronales convolucionales”, “data augmentation”, “cáncer de pulmón”, “diagnóstico” y “análisis de imágenes”. Se obtuvieron un total de 96 artículos que cumplían con los criterios establecidos para su inclusión en esta revisión. Se extrajeron y clasificaron los datos relevantes de cada artículo, tales como el título, el año, los autores, la revista, el objetivo, el método, los resultados y las conclusiones. Se utilizó la herramienta graphic_art para crear una tabla resumen con los datos extraídos y clasificados. Se presentan los resultados del mapeo sistemático en forma de gráficos y tablas, mostrando la distribución y la tendencia de las publicaciones según diferentes variables, como el año, el país, la revista, el tipo de red neuronal convolucional, el uso de data augmentation y el nivel de madurez. Se analizan los hallazgos más relevantes y se discuten las implicaciones, limitaciones y desafíos del uso de la inteligencia artificial y el aprendizaje profundo en el análisis de imágenes médicas para la detección del cáncer de pulmón.

3.2. Definición de términos

En este apartado se definen algunos términos que se utilizan a lo largo del artículo y que son relevantes para el tema de estudio. Estos términos son los siguientes:

- **Inteligencia artificial (IA):** Es la disciplina que se ocupa de crear sistemas o dispositivos capaces de realizar tareas que normalmente requieren de inteligencia humana, como el razonamiento, el aprendizaje, la percepción o la toma de decisiones.
- **Aprendizaje profundo (DL):** Es una rama de la inteligencia artificial que se basa en el uso de redes neuronales artificiales, que son modelos computacionales inspirados en el funcionamiento del cerebro humano, capaces de aprender a partir de datos y realizar tareas complejas, como la clasificación, la generación o la predicción.
- **Redes neuronales convolucionales (CNN):** Son un tipo especial de redes neuronales artificiales que se adaptan especialmente bien al procesamiento de imágenes, ya que utilizan filtros que extraen características relevantes de los píxeles.
- **Data Augmentation:** Es una técnica que consiste en generar nuevas imágenes a partir de las originales mediante transformaciones como rotación, escala o ruido. De esta forma, se aumenta la cantidad y la variedad de datos disponibles para el entrenamiento y se mejora la robustez del modelo ante variaciones en las imágenes de prueba.
- **Cáncer de pulmón:** Es una enfermedad que se produce cuando las células del tejido pulmonar crecen y se multiplican de forma anormal y descontrolada, formando tumores que pueden invadir otros órganos o tejidos. Existen dos tipos principales de cáncer de pulmón: el cáncer de pulmón de células no pequeñas (NSCLC) y el cáncer de pulmón de células pequeñas (SCLC). El NSCLC es el más común y se caracteriza por un crecimiento lento y una baja respuesta a la quimioterapia.

- **Diagnóstico:** Es el proceso de identificar y determinar la naturaleza y la causa de una enfermedad o un trastorno a partir de los signos, los síntomas, los antecedentes y los resultados de las pruebas médicas.
- **Análisis de imágenes:** Es el proceso de extraer información útil o relevante a partir de imágenes digitales mediante técnicas matemáticas, estadísticas o computacionales.

Para realizar esta revisión, se siguió el protocolo de búsqueda sistemática propuesto por Kitchenham y Charters (2007), que consiste en tres fases: planificación, ejecución y reporte. Se utilizó la herramienta search_web para buscar artículos científicos publicados desde el año 2015 hasta la actualidad que aborden el uso de la inteligencia artificial y el aprendizaje profundo en el campo de la radiología para la detección del cáncer de pulmón. La búsqueda se realizó en bases de datos científicas como PubMed, IEEEEXPLORE, Scopus y Web of Science, usando una cadena de búsqueda formada por los términos principales y los términos alternativos que se muestran en la Tabla 1. Se obtuvieron un total de 96 artículos que cumplían con los criterios establecidos para su inclusión en esta revisión. Se extrajeron y clasificaron los datos relevantes de cada artículo, tales como el título, el año, los autores, la revista, el objetivo, el método, los resultados y las conclusiones. Se utilizó la herramienta graphic_art para crear una tabla resumen con los datos extraídos y clasificados. Se presentan los resultados de la búsqueda sistemática en forma de gráficos y tablas, mostrando la distribución y la tendencia de las publicaciones según diferentes variables, como el año, el país, la revista, el tipo de red neuronal convolucional, el uso de data augmentation y el nivel de madurez. Se analizan los hallazgos más relevantes y se discuten las implicaciones, limitaciones y desafíos del uso de la inteligencia artificial y el aprendizaje profundo en el análisis de imágenes médicas para la detección del cáncer de pulmón.

Tabla 1. Términos principales y términos alternativos utilizados en la cadena de búsqueda

Término principal	Términos alternativos
Inteligencia artificial	IA, AI, artificial intelligence
Aprendizaje profundo	DL, deep learning
Redes neuronales convolucionales	CNN, convolutional neural networks
Data augmentation	DA, data augmentation
Cáncer de pulmón	Lung cancer

Término principal	Términos alternativos
Diagnóstico	Diagnosis
Análisis de imágenes	Image analysis

3.3. Criterios de inclusión y exclusión

Después de ejecutar los comandos de búsqueda se procedió a aplicar los criterios de inclusión (CI) y exclusión (CE) a todos los artículos encontrados. El paso necesario una vez obtenidos los artículos de las bases de datos es seleccionar los que aportan información para responder a las preguntas planteadas en este trabajo y descartar el resto. Este proceso fue iterativo y por cada artículo se aplicaron las diferentes reglas de selección. Cabe destacar que en este punto se seleccionaron un conjunto de artículos relevantes pero que fueron analizados en profundidad en la próxima sección cuando se aplican los filtros que son basados en los criterios aquí establecidos. Por esto, para completar la selección de trabajos se establecieron criterios de inclusión y exclusión según se muestra en la tabla a continuación:


Tabla 1: Criterios de inclusión y exclusión.

CRITERIOS DE INCLUSIÓN	CRITERIOS DE EXCLUSIÓN
CI1: Estudios en idioma inglés y español.	CE1: Estudios duplicados.
CI2: Estudios publicados durante el periodo comprendido entre 2015 y 2021.	CE2: Estudios que no se basen en el uso de imágenes médicas.
CI3: Estudios relacionados con el uso de la inteligencia artificial y el aprendizaje profundo en el análisis de imágenes médicas para la detección del cáncer de pulmón.	CE3: Artículos publicados previamente al 2015.
CI4: Campo de investigación: radiología e ingeniería biomédica.	CE4: Se descartan las publicaciones que no usen redes neuronales convolucionales o data augmentation para el análisis de imágenes médicas.
CI5: Tipo de documento: documento de conferencia y artículo.	CE5: Se descartan las publicaciones que no tengan como objetivo el diagnóstico del cáncer de pulmón o que no evalúen la precisión o la eficiencia del método propuesto.

4. Búsqueda de trabajos

Para la obtención de los artículos se siguió un procedimiento que consta de cuatro pasos que se resumen en la Tabla 4. El primer paso fue la definición de las preguntas de investigación, la creación de la cadena de búsqueda y los criterios de inclusión y exclusión para la selección de los artículos. La cadena de búsqueda se construyó utilizando los términos clave relacionados con el tema de investigación: inteligencia artificial, aprendizaje profundo, redes neuronales convolucionales, data augmentation, cáncer de pulmón, diagnóstico y análisis de imágenes. También se identificaron mapeos sistemáticos previos relacionados con el tema de investigación mediante una búsqueda manual en Google Scholar. El segundo paso fue la búsqueda de trabajos en cada una de las bases de datos elegidas, obteniendo un total de 96 artículos científicos publicados desde el año 2015 hasta la actualidad que abordan el uso de IA y DL en la ingeniería biomédica. Las bases de datos utilizadas fueron PubMed, Scopus, Web of Science y IEEE Xplore Digital Library. El tercer paso fue la aplicación de los criterios de inclusión y exclusión sobre los artículos encontrados. Este paso fue iterativo y se realizó en dos fases: primer y segundo filtro. En el primer filtro se analizaron el título, el abstract y las palabras clave de cada artículo, quedando 59 artículos. En el segundo filtro se analizaron la introducción y la conclusión de cada artículo, quedando 35 artículos. Estos son los artículos que se utilizaron para este mapeo sistemático. El cuarto paso fue la extracción y el análisis de los datos relevantes de los artículos seleccionados, siguiendo el protocolo de revisión establecido.

Tabla 4. Detalle del proceso de búsqueda y filtrado de artículos.



5 Síntesis de datos extraídos

Después de realizar el proceso de búsqueda, selección y clasificación de artículos detallado, se prosiguió con la sintetización de sus datos. De forma tal, de poder responder las preguntas de investigación planteadas y, a su vez, determinar si el Desarrollo de un Algoritmo de Inteligencia Artificial para la Detección de Patologías Relacionadas con el Cáncer de Pulmón a través del Análisis de Imágenes utilizando Redes Neuronales Convolucionales y Data Augmentation.

P1. ¿Qué tipo de red neuronal convolucional es la más adecuada para el análisis de imágenes médicas para la detección del cáncer de pulmón?

P2. ¿Qué beneficios tiene el uso de Data Augmentation en comparación con otras técnicas para aumentar la cantidad y la variedad de datos disponibles para el entrenamiento de la red neuronal convolucional?

P3. ¿Qué desafíos y limitaciones se presentan en la aplicación de la inteligencia artificial para el diagnóstico del cáncer de pulmón en la práctica clínica?

6. Conclusiones

Este mapeo sistemático de la literatura ha permitido un análisis exhaustivo de diversas investigaciones, con el objetivo de comprender el estado actual del desarrollo de algoritmos de inteligencia artificial en la detección de las patologías relacionadas con el cáncer de pulmón mediante el análisis de imágenes utilizando Redes Neuronales Convolucionales y Data Augmentation. Para abordar este objetivo, se plantearon varias preguntas de investigación que generaron una serie de interrogantes. Para responder a estas preguntas, se llevaron a cabo varios estudios.

En el primer estudio, se examinaron por separado los artículos que detectan patologías relacionadas con el cáncer de pulmón mediante el análisis de imágenes utilizando Redes Neuronales Convolucionales y Data Augmentation. Posteriormente, se estudiaron los trabajos que realizaron la detección de imágenes utilizando Redes Neuronales Convolucionales y Data Augmentation en el mismo sistema de evaluación.

A partir de estos estudios, se analizaron las funcionalidades adicionales que estos sistemas ofrecen para el control general. Finalmente, se examinaron las utilidades adicionales que estos desarrollos aportan al sector sanitario. Estos sistemas no solo alertan sobre diagnósticos favorables o desfavorables según sea el caso, sino que también hacen uso de técnicas de Deep Learning.

De este estudio se puede concluir que los algoritmos de inteligencia artificial para la detección de patologías relacionadas con el cáncer de pulmón pueden detectar patologías mediante el análisis de imágenes o a través de mecanismos de aprendizaje profundo. La utilización de conjuntos de datos de imágenes es la más común. También existen diferentes formas de detectar patologías, siendo las técnicas que utilizan detección y Machine Learning las más utilizadas. En este sentido, alternativamente, se podría considerar el uso de técnicas de aprendizaje automático supervisado, como las Máquinas de Vectores de Soporte (SVM), que han demostrado ser efectivas en la detección de patologías en imágenes médicas. Por otro lado, la aplicación de técnicas de aprendizaje profundo no supervisado, como las Redes Neuronales Autoencoder, podría ser un campo potencial para futuras investigaciones. Estas técnicas pueden ser útiles para descubrir patrones ocultos en los datos que pueden mejorar la precisión de la detección.

En cambio, estos pueden ser útiles para los especialistas en la evaluación de casos similares. Por ejemplo, la creación y el mantenimiento de una base de datos actualizados y diversos de imágenes pulmonares puede mejorar la eficacia del algoritmo al proporcionar una gama más amplia de casos para el entrenamiento y la validación del modelo. Esto también puede ayudar a los especialistas a comparar y contrastar casos similares, lo que puede ser beneficioso para el diagnóstico y el tratamiento. Otro factor que a menudo se pasa por alto son las cuestiones relacionadas con el registro de nuevos conjuntos de datos, los cuales pueden ser útiles para los especialistas en la evaluación de casos similares.

Este mapeo sistemático se llevó a cabo para conocer el estado actual de los sistemas que realizan la detección de patologías relacionadas con el cáncer de pulmón mediante

el análisis de imágenes utilizando Redes Neuronales Convolucionales y Data Augmentation. Dado que esta es la temática propuesta para una tesis de doctorado que se llevará a cabo en la Universidad Abierta Interamericana, este trabajo intentará abordar algunos de los problemas no resueltos mencionados anteriormente.

Bibliografía

R. Buettner, M. Bilo, N. Bay and T. Zubac, "A Systematic Literature Review of Medical Image Analysis Using Deep Learning," 2020 IEEE Symposium on Industrial Electronics & Applications (ISIEA), TBD, Malaysia, 2020, pp. 1-4, doi: 10.1109/ISIEA49364.2020.9188131.

M. F. Sohan and A. Basalamah, "A Systematic Review on Federated Learning in Medical Image Analysis," in IEEE Access, vol. 11, pp. 28628-28644, 2023, doi: 10.1109/ACCESS.2023.3260027.

A. AFFANE, M. -A. LEBRE, U. MITTAL and A. VACAVANT, "Literature Review of Deep Learning Models for Liver Vessels Reconstruction," 2020 Tenth International Conference on Image Processing Theory, Tools and Applications (IPTA), Paris, France, 2020, pp. 1-6, doi: 10.1109/IPTA50016.2020.9286639.

E. S. Kumar, C. S. Bindu, A. K. Somani et al., "Medical Image Analysis Using Deep Learning: A Systematic Literature Review", Emerging Technologies in Computer Engineering - Microservices in Big Data Analytics (ICETCE), vol. 985, pp. 81-97, 2019.

N. Brancati, G. de Pietro, M. Frucci and D. Riccio, "A Deep Learning Approach for Breast Invasive Ductal Carcinoma Detection and Lymphoma Multi-Classification in Histological Images", IEEE Access. Special Section on Deep Learning for Comput.-Aided Med. Diagnosis, vol. 7, pp. 44709-44720, 2019.

Vetriselvi, D., & Thenmozhi, R. (2023). A Systematic Literature Review on Deep Learning Based Medical Image Segmentation. International Journal of Intelligent Systems and Applications in Engineering, 11(5s), 519-526.

Gamboa-Cruzado, J., Rojas-Morales, M., López-Goycochea, J., Tinoco, E. C., Paucar-Carlos, G., & Damián, A. S. (2022). Systematic Literature Review on Convolutional Neural Networks for Vascular Surgeries. International Journal of Online & Biomedical Engineering, 18(12).

Razzak, M. I., Naz, S., & Zaib, A. (2018). Deep learning for medical image processing: Overview, challenges and the future. Classification in BioApps: Automation of Decision Making, 323-350.

Nishani, E., & Çiço, B. (2017, September). A Systematic Mapping Study of Computer Vision Approaches based on Deep Learning and Neural Network. In Proceedings of the 8th Balkan Conference in Informatics (pp. 1-8).

K. Petersen, R. Feldt, S. Mujtaba and M. Mattsson, (2008). Systematic Mapping Studies in Software Engineering. In Proceedings of the 12th International Conference on Evaluation and Assessment in Software Engineering. Italy, 68-77.

D. Moher, A. Liberati, J. Tetzlaff, and D. G. Altman (2009), “Preferred reporting items for systematic reviews and meta-analyses: The Prisma statement,” PLoS Med., vol. 6, no. 7, p. 264.

Tajbakhsh N, Shin JY, Gurudu SR, Hurst RT, Kendall CB, Gotway MB, Jianming Liang. Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning? IEEE Trans Med Imaging. 2016 May;35(5):1299-1312. doi: 10.1109/TMI.2016.2535302. Epub 2016 Mar 7. PMID: 26978662.

Michael Norval, Zenghui Wang, and Yanxia Sun. 2020. Pulmonary Tuberculosis Detection Using Deep Learning Convolutional Neural Networks. In Proceedings of the 3rd International Conference on Video and Image Processing (ICVIP '19).

Michael Norval, Zenghui Wang, and Yanxia Sun. 2020. Pulmonary Tuberculosis Detection Using Deep Learning Convolutional Neural Networks. In Proceedings of the 3rd International Conference on Video and Image Processing (ICVIP '19).

Xi Jiang and Hualei Shen. 2018. Classification of Lung Tissue with Cystic Fibrosis Lung Disease via Deep Convolutional Neural Networks. In Proceedings of the 2nd International Symposium on Image Computing and Digital Medicine (ISICDM 2018). Association for Computing Machinery, New York, NY, USA, 113–116.

Kaixuan Guo, Jun Wu, Wan Wan, Longfei Li, Tao Wang, Xingliang Zhu, and Lei Qu. 2021. Biomedical Image Segmentation Based on Classification Supervision. In 2021 13th International Conference on Bioinformatics and Biomedical Technology (ICBBT 2021). Association for Computing Machinery, New York, NY, USA, 22–27.

Z. Wu, Y. Yang, J. Gu and V. Tresp, "Quantifying Predictive Uncertainty in Medical Image Analysis with Deep Kernel Learning," 2021 IEEE 9th International Conference on Healthcare Informatics (ICHI), Victoria, BC, Canada, 2021, pp. 63-72, doi: 10.1109/ICHI52183.2021.00022.

Lujin Li, Hailiang Wang, Jinrong Hu, and Yan Zhang. 2021. Deformation Medical Image Registration Algorithm Based On Deep Prior Optical Flow Network. In Proceedings of the ACM Turing Award Celebration Conference - China (ACM TURC '21).

P. Dutta, P. Upadhyay, M. De and R. G. Khalkar, "Medical Image Analysis using Deep Convolutional Neural Networks: CNN Architectures and Transfer Learning," 2020 International Conference on Inventive Computation Technologies (ICICT), Coimbatore, India, 2020, pp. 175-180, doi: 10.1109/ICICT48043.2020.9112469.

N. Tajbakhsh et al., "Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning?," in *IEEE Transactions on Medical Imaging*, vol. 35, no. 5, pp. 1299-1312, May 2016, doi: 10.1109/TMI.2016.2535302.

Lujin Li, Hailiang Wang, Jinrong Hu, and Yan Zhang. 2021. Deformation Medical Image Registration Algorithm Based On Deep Prior Optical Flow Network. In *Proceedings of the ACM Turing Award Celebration Conference - China (ACM TURC '21)*. Association for Computing Machinery, New York, NY, USA, 210–215.

Chaunzwa, T. L., Hosny, A., Xu, Y., Shafer, A., Diao, N., Lanuti, M., ... & Aerts, H. J. (2021). Deep learning classification of lung cancer histology using CT images. *Scientific reports*, 11(1), 1-12.

Shimazaki, A., Ueda, D., & Choppin, A. (2022). Deep learning-based algorithm for lung cancer detection on chest radiographs using the segmentation method. *Sci Rep* 12: 727.

Kanavati, F., Toyokawa, G., Momosaki, S., Takeoka, H., Okamoto, M., Yamazaki, K., Takeo, S., Iizuka, O., & Tsuneki, M. (2021). A deep learning model for the classification of indeterminate lung carcinoma in biopsy whole slide images. *Scientific Reports*, 11(1), 81101.

Mikhael, P. G., Wohlwend, J., Yala, A., Karstens, L., Xiang, J., Takigami, A. K., ... & Barzilay, R. (2023). Sybil: a validated deep learning model to predict future lung cancer risk from a single low-dose chest computed tomography. *Journal of Clinical Oncology*, JCO-22. Cong, L., Feng, W., Yao, Z., Zhou, X. y Xiao, W. (2020).

Marconi Narváez, B. E. (2022). Diseño y evaluacion de un sistema de inteligencia artificial (IA) basado en redes neuronales convolucionales (CNN) para la detección y clasificación de nódulo tiroideo por ultrasonido.