

Inteligencia artificial para la detección de cáncer de pulmón: revisión descriptiva de estudios recientes (2021-2025)

Artificial intelligence for lung cancer detection: descriptive review of recent studies (2021–2025)

Kevin A. Serrano-Payán¹, Raúl F. Cruz-Moreno¹, Juan U. Gallardo-Zazueta¹, Francisco C. Delgado-Nieblas¹

¹Facultad de informática Culiacán, Universidad Autónoma de Sinaloa, México.

Autor de Correspondencia: Francisco C. Delgado-Nieblas, francisco.delgado@info.uas.edu.mx, **ORCID:** 0009-0007-5593-3341

Recibido: octubre 2025, **Aceptado:** octubre 2025, **Publicado:** noviembre 2025

Resumen:

El cáncer de pulmón es una de las principales causas de mortalidad mundial, y su detección temprana es clave para mejorar la supervivencia. Esta revisión de literatura sintetiza estudios recientes (2021–2025) sobre el uso de inteligencia artificial (IA) en el diagnóstico precoz del cáncer pulmonar, principalmente mediante análisis de imágenes médicas. Se recopilieron artículos de bases como Scopus, MDPI y Google Académico, en español e inglés, que emplearon modelos de aprendizaje-je profundo o automático. Los resultados destacan arquitecturas como EfficientNet y CNN+ViTs aplicadas a tomografías computarizadas, con precisiones superiores al 98 %, mientras que algoritmos clásicos como XGBoost y SVM mantienen alto desempeño en datos clínicos. Sin embargo, se identifican limitaciones relacionadas con la escasez de datos representativos, uso de datos sintéticos y falta de validación externa. En conjunto, la evidencia confirma el potencial de la IA para mejorar el diagnóstico temprano, aunque requiere mayor validación y solidez metodológica.

Palabras Clave:

Cáncer de Pulmón, Diagnóstico, Tomografía Computarizada (TC), Tomografía por Emisión de Positrones (PET), Rayos X, Inteligencia Artificial.

Abstract:

Lung cancer is one of the leading causes of mortality worldwide, and its early detection is key to improving survival rates. This literature review synthesizes recent studies (2021–2025) on the use of artificial intelligence (AI) in the early diagnosis of lung cancer, mainly through medical image analysis. Articles were collected from databases such as Scopus, MDPI, and Google Scholar, in both Spanish and English, employing deep or machine learning models. The results highlight architectures such as EfficientNet and CNN+ViTs applied to computed tomography, achieving accuracies above 98 %, while classical algorithms like XGBoost and SVM also show strong performance on clinical data. However, limitations were identified regarding the lack of representative data, use of synthetic data, and absence of external validation. Overall, the evidence confirms AI's potential to enhance early diagnosis, though greater methodological robustness and clinical validation are still required.

Keywords:

Lung Cancer, Diagnosis, Computed Tomography (CT), Positron Emission Tomography (PET), X-rays, Artificial Intelligence.

1. Introducción

El cáncer pulmonar continúa siendo una de las principales causas de muerte por cáncer en el mundo. Su detección en etapas tempranas aumenta la probabilidad de supervivencia en pacientes. Sin embargo, la identificación y detección manual del cáncer puede ser un proceso lento que puede resultar en un posible retraso en el diagnóstico y tratamiento, aumentando el riesgo de muerte del paciente.

Con el surgimiento y avance de la Inteligencia Artificial se han desarrollado distintos enfoques para la detección, clasificación y predicción del cáncer pulmonar para facilitar y mejorar los resultados. Esta amplia diversidad de enfoques, algoritmos y bases de datos ha generado un panorama fragmentado del conocimiento, dificultando la comparación y validación de resultados.

En este contexto, la presente revisión descriptiva busca:

- (i) resumir las principales técnicas de procesamiento de imágenes médicas que se han utilizado para mejorar la detección de nódulos pulmonares, incluyendo métodos de limpieza, segmentación y extracción de características, comparar los modelos de aprendizaje profundo más usados en los estudios revisados como CNN, EfficientNet, Vision Transformers y modelos híbridos, destacando sus resultados y particularidades,
- (ii) evaluar el rendimiento de estos modelos con base en métricas como precisión, sensibilidad, especificidad, F1-score y AUC, y discutir qué tan bien se adaptan a contextos clínicos reales,
- (iii) explorar cómo se están integrando estas soluciones con tecnologías como el Internet de las Cosas (IoT), y qué impacto tienen en la accesibilidad y rapidez del diagnóstico, especialmente en zonas con recursos limitados,
- (iv) identificar los principales obstáculos que enfrentan estas tecnologías, como la escasez de datos bien etiquetados, la falta de validación externa y la dificultad para interpretar los resultados de los modelos,
- (v) proponer posibles líneas de investigación que ayuden a desarrollar herramientas más confiables, comprensibles y útiles para el personal médico, con el objetivo de mejorar la atención a los pacientes y reducir la mortalidad por cáncer pulmonar.

El valor de esta revisión radica en su contribución al campo de la ciencia de datos aplicada a la medicina, al ofrecer una síntesis crítica que sirva de base para futuras

investigaciones orientadas a mejorar la precisión, eficiencia y accesibilidad de los sistemas de diagnóstico asistido por inteligencia artificial.

1.1 Preguntas orientadoras de la revisión

Para guiar el desarrollo de esta revisión, se plantean las siguientes preguntas descriptivo-exploratorias:

- ¿Qué modelos de inteligencia artificial se han aplicado recientemente en la detección temprana del cáncer pulmonar?
- ¿Qué técnicas de procesamiento y análisis de imágenes médicas han mostrado un mejor desempeño en la clasificación de imágenes médicas?
- ¿Qué tipo de datos se emplean en los estudios revisados, y qué impacto tiene la calidad, el tamaño y la diversidad de estos conjuntos en el rendimiento de los modelos?
- ¿Qué limitaciones técnicas y clínicas persisten en los estudios actuales?
- ¿Qué estrategias se están proponiendo para mejorar la interpretabilidad y aplicabilidad de los modelos de IA en la práctica clínica?

2. Trabajos Relacionados

2.1: Búsqueda bibliográfica

Se realizó una búsqueda cuidadosa de artículos científicos en bases de datos reconocidas como Scopus, MDPI y Google Académico. El objetivo fue encontrar estudios recientes que aplicaran inteligencia artificial en la detección temprana del cáncer pulmonar, especialmente aquellos enfocados en el análisis de imágenes médicas. Se utilizaron palabras clave como “lung cancer”, “classification”, “detection”, “predictive model”, “deep learning”, “transfer learning”, “pulmonary nodules”. También se aplicaron filtros por fecha (desde 2021), idioma (español e inglés) y tipo de publicación (artículos originales y revisiones científicas).

Además de la búsqueda directa, se revisaron las referencias de los artículos más relevantes para identificar otros estudios que no aparecieron en los resultados iniciales. Esta estrategia permitió reunir un conjunto sólido de investigaciones que sirven como base para el análisis y discusión de esta revisión de literatura.

2.1.1: El sitio web como plataforma inclusiva (Accesibilidad)

El sitio web se configura como una plataforma fundamentalmente inclusiva para la institución educativa, y su efectividad como servicio depende directamente de su accesibilidad. La implementación rigurosa de estándares internacionales, como las directrices WCAG

(Web Content Accessibility Guidelines), es esencial para garantizar que el contenido sea perceptible, operable, comprensible y robusto para todos los usuarios, independientemente de sus capacidades o de la tecnología de asistencia que utilicen.

Al construir una plataforma digital sin barreras, la universidad cumple con un mandato ético y legal, transformando su sitio de un simple punto de información a un servicio equitativo que asegura la plena participación de personas con discapacidades. Por lo tanto, la accesibilidad no es un añadido técnico, sino el pilar de la inclusión digital que define al sitio web como una verdadera plataforma de servicio universal.

2.2 Criterios de selección

Los artículos incluidos en esta revisión fueron seleccionados en base a distintos criterios. En primer lugar, se incluyeron aquellos artículos que fueron publicados desde el año 2021 en adelante para asegurar la revisión de propuestas actuales y relevantes en el campo. Solo se seleccionaron artículos que se enfocaran en la detección, predicción y clasificación del cáncer de pulmón mediante el uso de técnicas de Inteligencia Artificial. Además, solo se tomaron en cuenta artículos originales y fiables. Finalmente, se excluyeron aquellos artículos que no fueron escritos en inglés o español...

2.3 Recuperación de la información y fuentes documentales

Los artículos fueron organizados en una matriz comparativa según el tipo de arquitectura utilizada, tipo de imagen, contexto clínico de aplicación y métricas reportadas para facilitar la interpretación, comparación y discusión posterior.

Cuadro 1: Tabla comparativa de los artículos revisados

Título del artículo	Arquitectura utilizada	Tipo de dato	Contexto clínico de aplicación	Métricas reportadas
A novel hybrid deep learning method for early detection of lung cancer using neural networks [1]	CDCG-HNN (CNN + RNN), 3D-CNN + RNN	Tomografía computarizada (TC)	Clasificación de nódulos pulmonares en benignos, malignos y normales	Precisión 95%, Sensibilidad 87%, Selectividad 90%
Lung Cancer Risk Prediction with Machine Learning Models [2]	Múltiples modelos de Aprendizaje automático (Rotation Forest, Random Forest, SVM, MLP, etc.)	Datos clínicos tabulados	Predicción de riesgo a partir de síntomas y hábitos	Rotation Forest (Precisión, Sensibilidad, F-Measure, Exactitud) 97.1%, AUC 99.3%
Lung-ERNet: Lung cancer classification using EfficientNet from CT-scan images[3]	EfficientNet (B0-B4, transfer learning)	Tomografía computarizada (TC)	Clasificación en benigno, maligno y normal, visualización con GradCAM	Precisión 99.10%, F1-score 98.16%
Lung Cancer Detection Model Using Deep Learning Techniques[4]	DenseNet-121 + Autoencoders + MobileNet V3-Small	PET y TC combinadas	Clasificación de tipos de cáncer pulmonar en tiempo real	Precisión 98.6%, Recall 98.1%, F1-score 98.0%, Cohen's Kappa 95.8%
Lung Cancer Detection from X-Ray Images using Hybrid Deep Learning Technique[5]	CNN personalizada + SVM (OCNN-SVM)	Rayos X (Chest X-ray 14)	Clasificación binaria de imágenes con nódulos pulmonares	Precisión 98.70%, F1-score 98.76%, Recall 98.34%
Early Detection of Lung Nodules Using a Revolutionary Deep Learning Model[6]	HIFRCNN (Faster R-CNN + FPN)	Tomografía computarizada (TC)	Detección precisa de nódulos pulmonares en sistemas de telemedicina	Precisión >97%
Lung Cancer Detection and Classification Based on AlexNet CNN [7]	AlexNet-CNN (transfer learning)	Tomografía computarizada (TC)	Clasificación de tumores como benignos o malignos mediante segmentación morfológica	Exactitud de clasificación de 96%
Advancements in Early Detection of Lung Cancer in Public Health[8]	Múltiples modelos de aprendizaje automático (Análisis de regresión, XG-Boost, LightGBM, AdaBoost, Regresión Logística)	Datos clínicos tabulados	Predicción del riesgo de padecer cáncer pulmonar	Mejor desempeño:XGBoost (Exactitud 98.92%, Sensibilidad 95.5%, Especificidad 96.4%, F1-Score 95.66%)
Attention Enhanced InceptionV3-based Hybrid Deep Learning Model for Lung Cancer Detection [9]	Modelo híbrido (CNN+VITs) optimizada con bloques de InceptionNext	Tomografía computarizada (TC)	Clasificación de tumores(malignos, benignos, normal), Clasificación del cáncer(Adenocarcinoma, carcinoma de célula grande,carcinoma de célula escamosa) y clase normal	Exactitud 99.54%, Precisión 99.67%, Recall 99.6%,F1-score 98.48% (IQ-OTH/NCCD), Exactitud 98.41%, Precision 98.61%, Recall 98.35%, F1-score 98.48% (Kaggle Chest CT)
VER-Net: a hybrid transfer learning model for lung cancer detection using CT scan images[10]	VER-Net (combinación de VGG19, EfficientNetB0 y ResNet101)	Tomografía computarizada (TC)	Clasificación del cáncer(Adenocarcinoma, carcinoma de célula grande, carcinoma de célula escamosa) y clase normal	Exactitud de entrenamiento 97.74%, Exactitud de prueba/validación 91%, Valor de pérdida de entrenamiento 0.07%, Valor de pérdida de prueba/validación 0.34%, Precisión 92%, Recall 91%, F1-Score 91.3% (Promedio macro)

Fuente: Elaboración propia

3. Metodología

3.1 Organización y estructura de los datos

Para organizar la información de los artículos revisados, se construyó un diagrama de árbol que permite visualizar de forma jerárquica y clara los enfoques utilizados en la detección temprana del cáncer pulmonar. Esta estructura facilitó la clasificación de los estudios en cuatro ramas principales según el tipo de datos: tomografía computarizada (TC), imágenes combinadas PET/TC, rayos X, y datos clínicos e históricos. Cada una de estas ramas agrupa los modelos aplicados en ese contexto, junto con sus métricas de rendimiento y aplicaciones clínicas.




Figura 1: Diagrama de árbol por clasificación de los datos.
Fuente: Elaboración propia

3.2 Combinación de los resultados de diferentes orígenes

En el caso de las imágenes TC, se utilizaron modelos como CCDC-HNN[1], EfficientNet[3], HFR- CNN[6], AlexNet-CNN[7], CNN+ViT[9], y VER-Net[10], todos enfocados en tareas como la clasificación de nódulos, la detección en telemedicina, y la identificación de tipos de cáncer. Los resultados fueron notoriamente altos: por ejemplo, EfficientNet (Lung-EffNet) alcanzó una precisión del 99.10 % y un F1-score de 98.16 %, mientras que CNN+ViT logró métricas superiores al 98 % en dos conjuntos de datos distintos (IQ-OTH/NCCD y Kaggle Chest CT). Estos modelos muestran que las imágenes TC, combinadas con arquitecturas profundas, ofrecen una base sólida para el diagnóstico automatizado.

En el grupo de PET + TC, el modelo DenseNet-121 + MobileNet V3-Small[4] demostró un rendimiento igualmente competitivo, con una precisión del 98.6 % y un F1-score del 98.0 %. Su capacidad para realizar clasificación en tiempo real lo hace especialmente útil en entornos clínicos donde la velocidad y eficiencia son críticas.

Respecto a las radiografías de tórax, el enfoque OCNN-SVM (OCNN + SVM)[5] alcanzó una precisión del 98.70 % y un F1-score de 98.76 %, lo que demuestra que incluso con imágenes menos detalladas es posible obtener resultados confiables si se emplean modelos bien ajustados.

Por último, los estudios basados en datos clínicos tabulados aplicaron algoritmos clásicos como Rotation Forest, Random Forest, SVM, MLP, XGBoost, LightGBM, AdaBoost y regresión logística. Estos

modelos se enfocaron en la predicción de riesgo y la clasificación de cáncer a partir de variables clínicas, alcanzando métricas como AUC de 99.3 % y F1-scores superiores al 95 %. Esto confirma que los datos no visuales también pueden aportar valor diagnóstico cuando se procesan adecuadamente.

En conjunto, la combinación de estos resultados muestra que no existe un único enfoque dominante. Cada tipo de dato aporta ventajas distintas, y la elección del modelo depende del contexto clínico, la disponibilidad de información y el objetivo específico del diagnóstico. Esta integración de resultados ofrece una base sólida para el desarrollo de sistemas híbridos más precisos, versátiles y adaptables a distintos escenarios médicos.

4. Resultados

4.1 Argumentación crítica de los resultados: diseños, sesgos, limitaciones, conclusiones extraídas
Los estudios analizados presentan enfoques innovadores para la detección temprana del cáncer pulmonar mediante técnicas de inteligencia artificial. Sin embargo, al evaluar críticamente sus resultados, se identifican aspectos que afectan la confiabilidad, aplicabilidad clínica y validez metodológica de los modelos propuestos.

Diseños metodológicos y confiabilidad: La mayoría de los estudios emplean arquitecturas avanzadas como CNN, RNN, EfficientNet, DenseNet y modelos híbridos (VER-Net, HFR-CNN), alcanzando precisiones superiores al 95 %. Aunque estas cifras son prometedoras, muchos modelos fueron entrenados y evaluados en conjuntos de datos limitados o altamente controlados, lo que puede inflar artificialmente los resultados. La falta de validación externa en entornos clínicos reales limita la generalización de los hallazgos.

Sesgos y representatividad: Se detectan sesgos derivados del uso de datos sintéticos (SMOTE, GANs) para balancear clases o aumentar el tamaño del conjunto de entrenamiento. Si bien estas técnicas mejoran el rendimiento estadístico, pueden introducir patrones artificiales que no reflejan la variabilidad clínica real. Además, algunos estudios utilizan bases de datos públicas con escasa diversidad geográfica o demográfica, lo que compromete la representatividad de los modelos.

4.1.1 Limitaciones metodológicas comunes

Tamaño de muestra reducido: Algunos artículos trabajan con menos de 500 casos, lo que limita la robustez estadística.

Falta de validación cruzada externa: Aunque se emplean técnicas como validación cruzada interna (k-fold), pocos estudios prueban sus modelos en conjuntos de datos independientes.

Uso de datos sintéticos: La generación de ejemplos artificiales mediante SMOTE o GANs puede mejorar métricas como precisión o F1-score, pero no garantiza aplicabilidad clínica.

Ausencia de información clínica complementaria: Varios modelos se basan exclusivamente en imágenes, sin integrar variables clínicas como historial médico, síntomas o biomarcadores, lo que reduce su utilidad diagnóstica integral.

Aplicabilidad en la práctica clínica: Aunque algunos modelos como Lung-EffNet, MobileNet V3-Small y VER-Net destacan por su eficiencia computacional y precisión, su implementación en entornos hospitalarios requiere validación multicéntrica, análisis de costo-beneficio, y cumplimiento de normativas éticas y legales. La mayoría de los estudios aún se encuentran en fase experimental.

5. Conclusiones

La revisión de literatura muestra un potencial en la implementación de IA para la detección del cáncer de pulmón, mejorando la precisión de detección de nódulos pulmonares, agilizando el proceso y reduciendo el error humano. A través de la aplicación de modelos de aprendizaje profundo se pudo identificar nódulos pulmonares en imágenes de tomografías computarizadas y combinaciones de imágenes PET/TC.

Además, los enfoques basados en aprendizaje automático demostraron una capacidad predictiva cuando son utilizados con datos clínicos, la cual puede servir como complemento al análisis de imágenes. Sin embargo, aún se presentan desafíos como la limitada cantidad de datos y el uso de datos sintéticos para lidiar con este problema.

También, existen varios aspectos desconocidos como lo son la combinación óptima de información multimodal (imágenes y datos clínicos) para mejorar la precisión del diagnóstico y la interpretabilidad de los resultados, el rendimiento de estos modelos en entornos clínicos y que tan bueno es su desempeño en estos entornos donde los recursos son limitados. En cuanto a futuras investigaciones, se sugiere adoptar un enfoque en el desarrollo de modelos más explicables y transparentes haciendo uso de información multimodal y empleando

bases de datos más diversas.

6. Referencias

- [1] S. Wankhade y V. S., "A novel hybrid deep learning method for early detection of lung cancer using neural networks", *Healthcare Analytics*, vol. 3, pág. 100 195, 2023, ISSN: 2772-4425. DOI: <https://doi.org/10.1016/j.health.2023.100195>. dirección: <https://www.sciencedirect.com/science/article/pii/S277244252300062X>.
- [2] E. Dritsas y M. Trigka, "Lung Cancer Risk Prediction with Machine Learning Models", *Big Data and Cognitive Computing*, vol. 6, n.o 4, 2022, ISSN: 2504-2289. dirección: <https://www.mdpi.com/2504-2289/6/4/139>.
- [3] R. Raza et al., "Lung-EffNet: Lung cancer classification using EfficientNet from CT-scan images", *Engineering Applications of Artificial Intelligence*, vol. 126, pág. 106 902, 2023, ISSN: 0952-1976. DOI: <https://doi.org/10.1016/j.engappai.2023.106902>. dirección: <https://www.sciencedirect.com/science/article/pii/S0952197623010862>.
- [4] A. R. Wahab Sait, "Lung Cancer Detection Model Using Deep Learning Technique", *Applied Sciences*, vol. 13, n.o 22, 2023, ISSN: 2076-3417. DOI: 10.3390/app132212510. dirección: <https://www.mdpi.com/2076-3417/13/22/12510>.
- [5] V. Sreeprada y D. K. Vedavathi, "Lung Cancer Detection from X-Ray Images using Hybrid Deep Learning Technique", *Procedia Computer Science*, vol. 230, págs. 467-474, 2023, 3rd International Conference on Evolutionary Computing and Mobile Sustainable Networks (ICECMSN 2023), ISSN: 1877-0509. DOI: <https://doi.org/10.1016/j.procs.2023.12.102>. dirección: <https://www.sciencedirect.com/science/article/pii/S1877050923021075>.
- [6] D. Srivastava et al., "Early Detection of Lung Nodules Using a Revolutionized Deep Learning Model", *Diagnostics*, vol. 13, n.o 22, 2023, ISSN: 2075-4418. DOI: 10.3390/diagnostics13223485. dirección: <https://www.mdpi.com/2075-4418/13/22/3485>.
- [7] A. Agarwal, K. Patni y R. D., "Lung Cancer Detection and Classification Based on Alexnet CNN", en *2021 6th International Conference on Communication and Electronics Systems (ICCES)*, 2021, págs. 1390-1397. DOI: 10.1109/ICCES51350.2021.9489033.
- [8] M. Bhuiyan et al., "Advancements in Early Detection of Lung Cancer in Public Health: A Comprehensive

- Study Utilizing Machine Learning Algorithms and Predictive Models”, Journal of Computer Science and Technology Studies, vol. 6, p'ags. 113-121, ene. de 2024. DOI: 10.32996/jcsts.2024.6.1.12.
- [9] B. Ozdemir, E. Aslan e I. Pacal, “Attention Enhanced InceptionNeXt-Based Hybrid Deep Learning Model for Lung Cancer Detection”, IEEE Access, vol. 13, p'ags. 27 050-27 069, 2025. DOI: 10.1109/ACCESS.2025.3539122.
- [10] A. Saha, S. M. Ganie, P. K. D. Pramanik, R. K. Yadav, S. Mallik y Z. Zhao, “VER-Net: a hybrid transfer learning model for lung cancer detection using CT scan images”, BMC Medical Imaging, vol. 24, n.o 1, p'ag. 120, mayo de 2024, ISSN: 1471-2342. DOI: 10.1186/s12880-024- 01238-z. direcci' on: <https://doi.org/10.1186/s12880-024-01238-z>.