



Red de Investigación Estudiantil de la Universidad del Zulia
Revista Venezolana de Investigación Estudiantil

REDIELUZ

Sembrando la Investigación Estudiantil

Vol. 15 N° 2

Julio - Diciembre 2025



INTELIGENCIA ARTIFICIAL: CARACTERIZACIÓN, SEGMENTACIÓN DE NÓDULOS PULMONARES POR TOMOGRAFÍA DE ALTA RESOLUCIÓN

Artificial intelligence: characterization, segmentation of lung nodules through high-resolution

Miguel Ángel Hernández Neira, Edunice Mora López, Juan Pablo Monroy¹, Edilia Elena

Noguera Hernández

División de Estudios para Graduados de la Facultad de Medicina de la Universidad del Zulia. Maracaibo,
Venezuela.

ORCID: 0009-0003-0264-474X1

miguehdezneira@gmail.com, edunice@hotmail.com,
juanpmonroy7@gmail.com, eenh90@gmail.com

RESUMEN

Objetivo: evaluar la inteligencia artificial (IA) mediante tomografía de alta resolución en la segmentación y caracterización de nódulos pulmonares (NP) en pacientes referidos al Hospital Clínico de Maracaibo. Metodología: investigación descriptiva, transversal, prospectiva; muestra de 19 pacientes que requerían tomografía de tórax, empleando multidetector GE. Resultados: caracterización de NP mediante IA: respecto al tamaño de nódulos el promedio fue de 1,6 cm; con mayor número de casos (6) entre 0,5 a 1cm (31,6%), múltiples 10 (52,6%). Referente al tipo: sólidos de contorno regular 14 (73,7%), predominaron en lóbulos superiores, Derecho 8 (42,1%) e Izquierdo 5 (26,3%), sin correlación entre operadores con IA. Tipo de nódulos mediante IA: fueron sólidos (n=13), coincidiendo 7 con el primer operador y 12 con el segundo; igualmente el contorno regular de 13 casos detectados por la IA, 12 coincidieron con el segundo operador, arrojando concordancia de 92,3%. Segmentación mediante IA: fueron del Lóbulo Superior D (n=8), concordando 4 con el primer observador y 5 con el segundo, no hubo concordancia con 12 casos del primer operador y con 8 casos del segundo operador. Conclusión: la IA sigue siendo operador dependiente, requiriendo estudios de nuevos algoritmos basados en el aprendizaje profundo y nuevos paradigmas de lectura.

Palabras clave: Nódulos pulmonares, inteligencia artificial, tomografía de tórax

ABSTRACT

Objective: to evaluate artificial intelligence (AI) through high-resolution tomography in the segmentation and characterization of pulmonary nodules (NP) in patients referred to the Hospital Clinic de Maracaibo. Methodology: It was a descriptive investigation, cross-sectional, prospective. A sample of 19 patients over 18 years of age who required a chest tomography. A GE brand multidetector tomograph, were used. Results: they were 11 (57.9%) were female and 8 (42.1%) were male, with an average age of 65 ± 11.0 years. The characterization of the NPs through artificial intelligence, in terms of the size of the nodules the average was 1.6 cm, with the greatest number of cases 6 (31.6%) between 0.5 to 1 cm, multiple 10 (52.6%). Referring to the type; solid and contour; regular 14 (73.7%), predominated in upper lobes: Right 8(42.1%) and Left 5(26.3%). There was no correlation of the number of nodules between the operators with the AI. In relation to the type of nodules by the AI were Solid (n=13), coinciding 7 with the first operator and 12 with the second operator and likewise the regular contour of 13 cases detected by the AI, 12 coinciding on with the second operator, which yields a concordance of 92.3%. According to the segmentation through the AI, they were from the Upper Lobe D (n=8), agreeing 4 with the first observer and 5 with the second observer, noting that there was no agreement with 12 cases of the first operator and with 8 cases of the second operator. Conclusion: AI system remains operator dependent, future studies centralized in large-scale validation of new algorithms based on deep learning and new reading paradigms.

Key words: Pulmonary nodules, artificial intelligence, chest tomography.

Recibido: 17-09-2025 Aceptado: 30-09-2025

INTRODUCCIÓN

Los nódulos pulmonares son un problema importante de salud, la presencia de esta lesión presenta 80 posibilidades etiológicas que van desde enfermedades benignas hasta cánceres primarios o metastásicos pulmonares. La lesión maligna de pulmón es la principal causa de muerte relacionada con cáncer en todo el mundo, y las tasas de supervivencia a 5 años aún no superan el 20 % (Bray et al., 2018; Moyer et al., 2014). Para el 2018, la Sociedad Estadounidense del Cáncer informó que las tasas mundiales de incidencia y mortalidad eran más altas para el cáncer de pulmón que para cualquier otra forma de cáncer (Bray et al., 2018), situación que también se observa en Venezuela.

Al respecto, la Sociedad Anticancerosa de Venezuela (SAV), a través del Departamento de Educación y Prevención, en alianza con el Centro de Estadística y Matemática Aplicada (CEsMA) de la Universidad Simón Bolívar, unieron sus esfuerzos para elaborar la tercera edición del Boletín de los Pronósticos de la Mortalidad e Incidencia de Cáncer en Venezuela (Sociedad Venezolana Anticancerosa, 2019), para informar oportunamente sobre la evolución estadística del cáncer en el país, contribuir a medir la carga de la enfermedad y concientizar sobre el cáncer como un problema de salud pública, referenciando que el cáncer pulmonar continúa siendo un problema de salud importante por su elevada morbilidad y mortalidad.

Por lo tanto, es necesario contar procedimientos no invasivos que contribuyan a discernir si un nódulo pulmonar es benigno o maligno, la evaluación inicial generalmente involucra a un radiólogo que usa características clínicas y radiográficas, a menudo de una tomografía computarizada (TC) para determinar el tratamiento posterior, por ejemplo la vigilancia por TC, la biopsia. (Aberle et al., 2011).

Sin embargo, distinguir la malignidad de las características clínicas y radiográficas puede ser un desafío y se están considerando métodos novedosos, incluida la inteligencia artificial; la cual es una rama de la informática que se ocupa del desarrollo de sistemas que pueden realizar tareas que normalmente requerirían inteligencia humana, como la resolución de problemas, el razonamiento y el reco-

nocimiento, (Lachance y Walter, 2020) con algoritmos para leer tomografías computarizadas que, a menudo, incluyen un sistema de aprendizaje automático (por ejemplo, máquina de vectores de soporte (SVM), redes neuronales artificiales (aprendizaje profundo, incluida la red neuronal convolucional o CNN).

Los avances continuos en inteligencia artificial pueden ayudar a los médicos a detectar y diagnosticar nódulos pulmonares (Zhang et al., 2019 y Ather et al., 2020). Tomando en cuenta tales argumentos, se realizó este estudio con el objetivo de evaluar a la Inteligencia artificial en la estadificación y segmentación de los nódulos pulmonares y a su vez demostrar que aún este procedimiento necesita de un operador dependiente, cuyo resultado serviría para validar este procedimiento y aportar información oportuna sobre la probabilidad de un nódulo pulmonar maligno. Finalmente; los postulados y construcciones teóricas derivadas de tal investigación, se muestran en el presente documento, en el cual se puede dar cuenta de los fundamentos teóricos, la metodología, los resultados y las conclusiones, todo ello con la meticulosidad que todo artículo científico reviste.

DESARROLLO

Nódulo Pulmonar (NP): Definición, Diagnóstico y Manejo

Un nódulo pulmonar se define clásicamente como una lesión radiológica de menos de 3 cm rodeada de parénquima pulmonar (MacMahon et al., 2017). La masificación de los métodos de diagnóstico por imágenes, como la tomografía computarizada (TC) de tórax, ha aumentado la detección de nódulos pequeños (<2 cm) que no son visibles en la radiografía de tórax. Estos nódulos pueden ser tanto sólidos como sub-sólidos, cada uno tiene diferente comportamiento, velocidad de crecimiento y probabilidad de malignidad (MacMahon et al., 2017; Gould et al., 2013). El diagnóstico diferencial de estos nódulos es amplio e incluye, además del cáncer, metástasis y lesiones benignas como las infecciosas, inflamatorias, vasculares, traumáticas y congénitas (MacMahon et al., 2017).

Las características radiológicas y su comportamiento temporal permiten sospechar su etiología. Por ejemplo, los nódulos calcificados y bien delimitados que no crecen sugieren lesiones benignas, mientras que los espiculados o irregulares que cre-

cen en controles sucesivos sugieren una etiología maligna (Chartrand et al., 2017; Wu et al., 2019). Para su estudio racional se han desarrollado algoritmos de decisión que incluyen exámenes como TC seriados, PET/CT y biopsias, ya sea por fibrobroncoscopia, EBUS, percutánea o quirúrgica (Chartrand et al., 2017; Wu et al., 2019; Patel, 2013). Por lo tanto, es de suma importancia diferenciar los nódulos benignos de aquellos sospechosos de cáncer y aplicar los algoritmos de manejo y seguimiento aceptados actualmente.

Inteligencia Artificial (IA) y su Aplicación en la Imagenología Médica

La inteligencia artificial (IA) se define como el campo de estudio de dispositivos inteligentes que perciben su ambiente y toman acciones para maximizar su oportunidad de cumplir objetivos (16). El término fue acuñado por John McCarthy en 1956 (Gould et al., 2013). Su aplicación en imagenología médica se ha visto impulsada por el desarrollo del aprendizaje profundo (deep learning), una rama de la IA basada en redes neuronales artificiales (Chang, 2018; Zaharchuk et al., 2018). Con el mejoramiento del hardware, los modelos de aprendizaje profundo han demostrado ser más eficaces en el reconocimiento de imágenes que los basados en IA convencional (Zaharchuk et al., 2018).

El aprendizaje profundo cobró impulso en 2012 cuando Krizhevsky y colaboradores implementaron con éxito una red neuronal convolucional (CNN) que superó a los algoritmos de la competencia de forma sustancial (Krizhevsky et al., 2012). Actualmente, la CNN es la metodología de elección para el análisis de imágenes médicas, y su rendimiento alcanza o incluso supera el de los humanos en un número creciente de tareas (Yasaka et al., 2016). La publicación de los primeros algoritmos para la detección de nódulos pulmonares en TC data de hace más de dos décadas, y el número de estudios sobre este tema ha aumentado notablemente en los últimos 10 años, principalmente debido a los avances en el aprendizaje profundo, la disponibilidad de conjuntos de datos públicos y la implementación inminente de la detección del cáncer de pulmón (Yasaka et al., 2016).

Rendimiento de la IA en la Detección, Clasificación y Predicción de Nódulos

Detección de Nódulos

El primer paso en el flujo de trabajo hacia el diagnóstico del cáncer de pulmón es la detección de todos los nódulos pulmonares. Se ha documentado que los radiólogos no encuentran todos los nódulos, y existe un desacuerdo considerable sobre lo que constituye un nódulo pulmonar (Pinsky et al., 2013). La tarea es difícil para los humanos, especialmente en imágenes complejas, con la presencia de vasos y vías respiratorias, y cuando el tiempo apremia (Setio et al., 2017). Numerosos estudios sobre algoritmos de IA para la detección de nódulos pulmonares han sido publicados (Setio et al., 2020; Li et al., 2019). Desafíos como el Lung Nodule Analysis 2016 (LUNA16), que utilizó 888 escaneos de la base de datos LIDC/IDRI, han permitido comparar diferentes enfoques metodológicos (Setio et al., 2017; Armato et al., 2011). En este desafío, el mejor algoritmo alcanzó una sensibilidad del 97,2 % con un falso positivo por escaneo en promedio (Armato et al., 2011). Estudios comparativos, aunque en su mayoría de hace más de una década, mostraron que los algoritmos tenían sensibilidades ligeramente inferiores o equivalentes a los radiólogos, pero con una tasa de falsos positivos notablemente más alta (Krizhevsky et al., 2012; Rubin et al., 2005).

Clasificación y Medición de Nódulos

Después de la detección, los nódulos se estratifican en grupos de riesgo de malignidad según su tamaño y tipo. La medición o clasificación automática de nódulos no se incluyó como tarea en el desafío ANODE09 o LUNA16 (Setio et al., 2017). Con el objetivo de una clasificación automática, autores como Ciompi et al. (2017) desarrollaron un algoritmo de IA para diferenciar entre seis tipos de nódulos (sólido, parcialmente sólido, no sólido, perifisural, calcificado y espiculado), con un rendimiento que se encontraba dentro de la variabilidad interobservador de cuatro lectores humanos experimentados.

La medición manual de los diámetros del nódulo es propensa a la variabilidad. Aunque los métodos de segmentación volumétrica son más reproducibles, no se han utilizado ampliamente en la mayoría de los ensayos de detección de cáncer de pulmón

(Devaraj et al., 2017). Sin embargo, se ha encontrado que el diámetro medio derivado de un sistema de detección asistida por computadora (CAD) es tan predictivo de malignidad como el volumen derivado del mismo cuando se usa en un modelo de regresión logística multivariable (Tammemagi et al., 2019).

Predicción de Malignidad

El objetivo final de la detección por TC es predecir el cáncer de pulmón (Chung et al., 2018). El modelo estadístico de riesgo más conocido es el modelo de Brock (PanCan; McWilliams et al., 2013). Sin embargo, aunque el modelo de Brock incorpora varios predictores basados en la demografía del paciente, tamaño, tipo y la morfología del nódulo, estudios previos han demostrado que los radiólogos pueden evaluar con mayor precisión el riesgo de malignidad de un nódulo (Chung et al., 2017; Van Riel et al., 2017). No obstante, cuando se pidió a los radiólogos que caracterizaran los signos de malignidad, no se encontró un consenso 46. En el desafío Long (Van Riel et al., 2017) de la Universidad de Chicago, de 11 algoritmos de IA, solo tres obtuvieron un área bajo la curva (AUC) estadísticamente superior al azar, mientras que seis radiólogos obtuvieron AUC entre 0.70 y 0.85, superando a los algoritmos (Van Riel et al., 2017). No obstante, un estudio del Tagle Data Sciense Bowl (2017) encontró que los lectores humanos expertos se desempeñaron solo ligeramente mejor que los tres principales algoritmos de IA en la predicción de un diagnóstico de cáncer de pulmón en el plazo de un año (Jacobs et al., 2019).

METODOLOGÍA

Se realizó una investigación descriptiva con diseño transversal y prospectivo, con una población conformada por los pacientes que ameritan tomografía de tórax, referidos al Servicio de Estudios por Imágenes del Hospital Clínico de Maracaibo, en el lapso de octubre a noviembre 2022, cuya muestra quedó constituida por 19 pacientes que representan a la población en estudio y cumplieron con los criterios de inclusión y exclusión determinados. Se incluyeron pacientes mayores de 18 de ambos sexos, de cualquier estrato social que ameritaron tomografía de tórax; y se excluyeron los pacientes con patologías pulmonares por covid, enfermedad bronco obstructiva y metástasis, así como los que se negaron a participar en el estudio.

La TAC se realizó en un tomógrafo multidetector marca GE, modelo Discovery de 16 cortes, con software (General Electric, AW, volumeshare 7 (AW4.7) Lung VCARD. El paciente se ubicó en posición supina, en inspiración máxima, con adquisición volumétrica, en ventana pulmonar y mediastinal. Los principales parámetros de escaneo fueron los siguientes: voltaje del tubo = 120 kVp, con modulación automática de la corriente del tubo (70-120 más), Pich de 1, espesor de corte de 1 mm y matriz de 512 × 512. Todas las imágenes fueron reconstruidas con un algoritmo de alta resolución espacial.

El sistema de inteligencia artificial empleado consta de dos módulos: un módulo de detección y un módulo de segmentación. El módulo de detección genera el nódulo pronosticado con un cuadro delimitador tridimensional y la malignidad del nódulo. Basándose en el cuadro delimitador, la región de interés de los nódulos detectados se calculó y pasó al módulo de segmentación de nódulos, que genera una máscara de nódulo tridimensional reconstruida para cada nódulo detectado. Las características morfológicas se calculan en función de la máscara tridimensional de salida.

Todas las imágenes de TC fueron obtenidas por médicos con experiencia en el diagnóstico de imágenes de tórax. Luego fueron examinadas en forma doble ciego por dos radiólogos experimentados. Todos los nódulos pulmonares se clasificaron según la densidad de la lesión y se evaluaron subjetivamente en función de algunas características. Los pacientes para los que la diferencia entre el número de signos en la HRCT objetivo y la imagen convencional sea >1 se incluyeron en el grupo de visibilidad mejorada (es decir, se observaron más signos durante el escaneo objetivo). Los pacientes restantes fueron asignados al mismo grupo de visibilidad.

Los datos se recolectaron en un instrumento tipo formulario evaluado y validado por dos especialistas del área y uno especialista en metodología, siendo sometido a la prueba de confiabilidad respectiva. Los datos fueron analizados a través de medidas de tendencia central, mediante el uso de cifras absolutas y porcentajes. Se empleó el programa estadístico SPSS, versión 23. Posteriormente, se realizó el análisis e interpretación de los resultados que se expresaron en tablas.

RESULTADOS

Al evaluar la caracterización y segmentación de los nódulos pulmonares mediante la inteligencia artificial, en cuanto al tamaño de los nódulos el promedio fue de 1,6 cm, con mayor número de casos 6 (31,6%) con tamaño entre 0,5 a 1cm, >1 a 1,5 cm 4 (21,0%), > 1,5 a 2 cm 4 (21,0%), > 2 a 2,5 cm 2 (10,5%), < 0,5 cm 1 (5,3%), > 2,5 cm 2 (10,6%). Respecto al número, fueron; únicos 9 (47,4%) y múltiples 10 (52,6%). Referente al tipo; sólidos 13 (68,4%), mixtos 5 (26,3%) y esmerilados 1(5,3%). Según el contorno; regular 14 (73,7%), irregular 3 (15,8%) y espiculados 2 (10,5%). Sobre la segmentación; Lóbulo Superior Derecho 8(42,1%), Lóbulo Superior Izquierdo 5(26,3%), Lóbulo Inferior Izquierdo 3(15,8%), Lóbulo Inferior Derecho 2(10,5%) y Lóbulo Medio Derecho 1(5,3%).

Al analizar la relación del tamaño de los nódulos pulmonares detectados mediante la IA y los observados por los operadores se evidencia que no hubo concordancia entre IA y el tamaño observado por los operadores, notándose que el primer operador visualizó 9(47,4%) casos con un tamaño superior al reportado por la IA, con una diferencia promedio de $+0,7 \pm 0,35$ y 9(47,4%) casos con un tamaño inferior al reportado por la IA, con una diferencia promedio de $-1,0 \pm 0,33$ cm y el segundo operador visualizó 7(36,8%) casos con un tamaño superior al reportado por la IA, con una diferencia promedio de $+0,4 \pm 0,34$ y 11(57,9%) casos con un tamaño inferior al reportado por la IA, con una diferencia promedio de $-0,5 \pm 0,36$ $-1,0 \pm 0,33$ cm. Notándose que 1(5,3%) paciente con nódulo pulmonar detectado por la IA, no fue observado por los operadores.

Con respecto a la relación del número, tipo, contornos y segmentación de los nódulos pulmonares detectados mediante la IA y operadores, se muestra que referente a la IA, determinó 9 nódulos únicos y de ellos coincidieron 3 casos con el primer operador y 5 casos con el segundo operador. Nódulos múltiples por la IA fueron 10 de los cuales 4 concordaron con el primer operador y 3 con el segundo operador, evidenciándose que no hubo correlación del número de nódulos con la IA, en 12 casos del primer operador y con 11 casos del segundo operador.

En relación al tipo de nódulos mediante la IA fueron sólidos (n=13), coincidiendo 7 con el primer operador y 12 (92,3%) con el segundo operador. No hubo concordancia con 12 casos del primer operador y con 5 casos del segundo operador. Referente

al contorno de nódulo mediante la IA, fueron regular (n=13) coincidiendo 11 con el primer operador y 12 (92,3%) con el segundo operador. No hubo concordancia con 7 casos del primer operador y con 5 casos del segundo operador.

De acuerdo a la segmentación de los nódulos mediante la IA fueron del lóbulo superior D (n=8), concordando 4 con el primer observador y 5 con el segundo observador, notándose que en cuanto a la segmentación no hubo concordancia con 12 casos del primer operador y con 8 casos del segundo operador.

CONCLUSIONES

La caracterización y segmentación de los nódulos pulmonares mediante la inteligencia artificial, en cuanto al tamaño de los nódulos el promedio fue de 1,6 cm, y más de un tercio de ellos el tamaño osciló entre 0,5 a 1 cm, en su mayoría fueron múltiples. Prevaleció el tipo sólido, de contornos regulares y ubicados en lóbulos superiores.

No hubo concordancia del tamaño del nódulo entre inteligencia artificial y los operadores con el 92,3%; hubo concordancia de los nódulos sólidos y contorno regular entre la inteligencia artificial con uno de los operadores. Fue baja la concordancia del tipo y segmentación entre la inteligencia artificial y los operadores.

Finalmente, debido al resultado del estudio se deduce que el sistema de IA sigue siendo un operador dependiente.

REFERENCIAS BIBLIOGRÁFICAS

- Aberle DR, Adams AM, Berg CD, Black WC, Clapp JD, Fagerstrom RM, et al. (2011) Reduced Lung-Cancer Mortality With Low-Dose Computed Tomographic Screening. *N Engl J Med*; 365(5):395–409. doi: 10.1056/NEJMoa1102873
- Armato SG, 3rd, McLennan G, Bidaut L. (2011) The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): a completed reference database of lung nodules on CT scans. *Med Phys* 2011;38:915–31. 10.1118/1.3528204
- Ather S, Kadir T, Gleeson F. (2020) Artificial Intelligence and Radiomics in Pulmonary Nodule Management: Current Status and Future Applications. *Clin Radiol* 75(1):13–9. doi: 10.1016/j.crad.2019.04.017

- Bray F, Ferlay J, Soerjomataram I, Siegel RL, Torre LA, Jemal A. (2018) Global Cancer Statistics 2018: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries. *CA Cancer J Clin* (2018) 1168(6):394–424. doi: 10.3322/caac.21492
- Chang, P. (2018) What to make of the increased hype surrounding AI in radiology. *Radiology Business*. Disponible en: <https://www.radiologybusiness.com/sponsored/9667/topics/imaging-informatics/rsna-2018-hype-ai-radiology>
- Chartrand G, Cheng PM, Vorontsov E. (2017) learning: a primer for radiologists. *Radiographics*. 37(7):2113–2131
- Chung K, Mets OM, Gerke PK. (2018) Brock malignancy risk calculator for pulmonary nodules: validation outside a lung cancer screening population. *Thorax*; 73 (1):857-863.
- Ciompi F, Chung K, van Riel S. (2017) Towards automatic pulmonary nodule management in lung cancer screening with deep learning. *Sci Rep* 2017;7:46479. 10.1038/srep46479.
- Devaraj A, van Ginneken B, Nair A. (2017) Use of Volumetry for Lung Nodule Management: Theory and Practice. *Radiology*;284:630-44. 10.1148/radiol.2017151022
- Gould MK, Donington J, Lynch WR. (2013) Evaluation of individuals with pulmonary nodules: when is it lung cancer? Diagnosis and management of lung cancer, 3rd ed: American College of Chest Physicians evidence-based clinical practice guidelines. *Chest*; 143 :(5):e93S–e120S.
- Jacobs C, Scholten E, Schreuder A. (2019) An observer study comparing radiologists with the prize-winning lung cancer detection algorithms from the 2017. Kaggle Data Science Bowl. Annual Meeting of the Radiological Society of North America, 2019.
- Krizhevsky A, Sutskever I, Hinton G E. (2012) “Imagenet classification with deep convolutional neural networks. Disponible en: <https://dl.acm.org/doi/10.5555/2999134.2999257>.
- Lachance, Chantelle C., Walter, Melissa. (2020) Artificial Intelligence for Classification of Lung Nodules: A Review of Clinical Utility, Diagnostic Accuracy, Cost-Effectiveness, and Guidelines. Canadian Agency for Drugs and Technologies in Health. Disponible en: <https://pubmed.ncbi.nlm.nih.gov/33074628/>
- Li D, Mikela Vilmun B, Frederik Carlsen J, et al. (2019) The Performance of Deep Learning Algorithms on Automatic Pulmonary Nodule Detection and Classification Tested on Different Datasets That Are Not Derived from LIDC-IDRI: A Systematic Review. *Diagnostics (Basel)*; 9:207. 10.3390/diagnostics9040207
- MacMahon H, Naidich DP, Goo JM. (2017) Guidelines for management of incidental pulmonary nodules detected on CT images: from the Fleischner Society *Radiol.*; 284(1):228–243.
- Moyer VA, Moyer VA, LeFevre ML, Siu AL, Peters JJ, Baumann LC. (2014) Screening for Lung Cancer: U.S. Preventive Services Task Force Recommendation Statement. *Ann Intern Med*; 160(5):330–8. Disponible en: doi: 10.7326/M13-2771
- McWilliams A, Tammemagi MC, Mayo JR, et al. (2013) Probability of cancer in pulmonary nodules detected on first screening CT. *N Engl J Med*;369:910-9. 10.1056/NEJMoa1214726
- Patel, V.K. (2013) A Practical Algorithmic Approach to the Diagnosis and Management of Solitary Pulmonary Nodules Diagnosis of Pulmonary Nodules Part 2: Pretest Probability and Algorithm. *Chest*, 143, pp. 840 <http://dx.doi.org/10.1378/chest.12-1487>
- Sociedad Venezolana Anticancerosa (2019). Boletín de los Pronósticos de la Mortalidad e Incidencia del Cáncer en Venezuela 2019. 3^a Edición - Centro de Estadística y Matemática Aplicada de la Universidad Simón Bolívar. Disponible en: www.cancervenezuela.org
- Pinsky PF, Gierada DS, Nath PH. (2013) National lung screening trial: variability in nodule detection rates in chest CT studies. *Radiology*; 268:865-73.
- Rubin GD, Lyo JK, Paik DS. (2005) Pulmonary nodules on multi-detector row CT scans: performance comparison of radiologists and computer-aided detection. *Radiology* 2005; 234:274-83. 10.1148/radiol.2341040589
- Setio AAA, Traverso A, de Bel T. (2017) Validation, comparison, and combination of algorithms for automatic detection of pulmonary nodules in computed tomography images: The LUNA16 challenge. *Med Image Anal* 2017;42:1-13.
- Tammemagi M, Ritchie AJ, Atkar-Khattra S. (2019) Predicting Malignancy Risk of Screen-Detected Lung Nodules-Mean Diameter or Volume. *J Thorac Oncol*; 14: 203-211.

Van Riel SJ, Ciompi F, Winkler Wille M. (2017) Malignancy risk estimation of pulmonary nodules in screening CTs: Comparison between a computer model and human observers. *PLoS One* 2017; 12:e0185032.

Wu W, Hu H, Gong J, Li X, Huang G, Nie S. (2019) Malignant-benign classification of pulmonary nodules based on random forest aided by clustering analysis. *Phys Med Biol*; 64(3):035017.

Yasaka K, Katsura M, Hanaoka S, Sato J, Ohtomo K. (2016) High-Resolution CT With New Model-Based Iterative Reconstruction With Resolution Preference Algorithm in Evaluations of Lung Nodules: Comparison With Conventional Model-Based Iterative Reconstruction and Adaptive Statistical Iterative Reconstruction. *Eur J Radiol* (2016) 85(3):599–606. doi: 10.1016/j.ejrad.2016.01.001

Zaharchuk G, Gong E, M. Wintermark, M. (2018) Deep Learning in Neuroradiology. *Am. J. Neuroradiol*, October 2018, 39 (10) 1776-1784. <https://doi.org/10.3174/ajnr.A5543>

Zhang C, Sun X, Dang K, Li K, Guo XW, Chang J, et al. (2019) Toward an Expert Level of Lung Cancer Detection and Classification Using a Deep Convolutional Neural Network. *Oncologist* (2019) 24(9):1159–65. doi: 10.1634/theoncologist.2018-0908.