



Editorial

Inteligencia artificial en las enfermedades respiratorias

Artificial Intelligence in Respiratory Diseases



La aplicación de técnicas de inteligencia artificial (IA) en diversos campos de la medicina ha crecido de manera significativa en los últimos años¹. Este crecimiento se ha debido principalmente al progreso de la computación de altas prestaciones y al desarrollo de las técnicas de aprendizaje profundo (DL, por sus siglas en inglés), un subconjunto de algoritmos de IA que utilizan redes neuronales para aprender a resolver tareas específicas a partir de bases de datos etiquetadas por expertos.

Un campo de la medicina que está pasando por un cambio de paradigma por la aplicación de la IA es la imagen médica, ya que el análisis de las diferentes modalidades de adquisición de imágenes mediante algoritmos de procesamiento de imagen tradicionales (umbralización, filtrados y utilización de atlas de geometría, entre otros) no alcanzaba a resolver problemas complejos de manera eficiente, como la detección con una alta exactitud de las cisuras pulmonares en un estudio de tomografía computarizada (TC). Este escenario ha cambiado significativamente en los últimos años gracias a las redes neuronales convolucionales (CNN, por sus siglas en inglés), que son un tipo particular de algoritmos de DL que aprenden filtros convolucionales a partir de bases de datos de imágenes etiquetadas. Estos filtros son capaces de extraer una gran cantidad de características de las imágenes, cuya combinación en un proceso secuencial permite la interpretación de patrones complejos, como los presentes en las imágenes médicas.

Las CNN presentan una alta versatilidad, lo que ha permitido que en la actualidad se hayan abierto multitud de líneas de investigación en tareas como reducción de tiempos y mejora de la calidad en la adquisición de diversas modalidades de imagen, disminución de contraste administrado al paciente en determinadas pruebas, cribado de casos, detección de enfermedades y segmentación de regiones de interés. La investigación en algunos de estos campos ha llegado a un nivel tan avanzado de desarrollo que actualmente se encuentran productos en el mercado completamente basados en IA, cuyo beneficio en la práctica clínica ya ha sido demostrado mediante los procesos de validación pertinentes para poder ser considerados como productos sanitarios.

La clasificación consiste en asignar a los casos de entrada a una CNN una probabilidad de pertenecer a una clase, es decir, se estima en qué grado las imágenes contienen patrones que son comunes a una clase. En imagen médica, la clasificación automática de radiografías de tórax con CNN es un campo al que se le ha dedicado especial atención, tanto por la comunidad científica como por la industria. Además, se han liberado grandes bases de datos públicas con cientos de miles de imágenes etiquetadas para impulsar el desarrollo de nuevos algoritmos en esta materia. Uno de los

principales catalizadores de este interés es la falta de recursos en los departamentos de radiología para informar “de” la gran cantidad de radiografías de tórax que se adquieren en rutina clínica². Por este motivo, los algoritmos de clasificación de radiografías de tórax se han desarrollado para realizar un cribado previo de imágenes de sujetos sanos para que los radiólogos sean capaces de centrar sus esfuerzos en informar los casos potencialmente patológicos. El impacto de este tipo de algoritmos en la práctica clínica ya se ha medido en diferentes estudios, los cuales concluyen que utilizando estas herramientas se puede reducir el tiempo de informado de estudios críticos de 11,2 a 2,7 días³ y que el área bajo la curva de los radiólogos expertos sube de 0,93 a 0,96 en la clasificación de estudios entre normales y patológicos⁴.

La segmentación consiste en delinear una región anatómica, objetivo que es posible automatizar con CNN ya que estas pueden asignar una probabilidad a cada vóxel de la imagen de pertenecer o no a la región de interés. En la cuantificación de enfermedades respiratorias mediante imagen la segmentación de los pulmones es un paso fundamental que permite que los algoritmos de análisis no se vean influidos por regiones extra-pulmonares. La automatización de este proceso mediante CNN ha permitido obtener resultados sin precedentes tanto en radiografías de tórax como en TC, obteniendo un coeficiente de solapamiento entre la segmentación manual de los radiólogos y la estimada por las CNN de 0,975⁵ y 0,968⁶, respectivamente, siendo 1 el valor de solapamiento perfecto. Una de las técnicas de análisis de imagen que se ha visto positivamente impactada por la mejora de la segmentación automática de pulmones en TC con CNN es la cuantificación automática de enfisema. Esto se debe a que esta técnica se basa en el conteo de vóxeles de los pulmones en TC que están por debajo de un determinado umbral de Unidades Hounsfield, por tanto, la estimación precisa de los vóxeles que pertenecen al pulmón es fundamental para un cálculo correcto del volumen de enfisema.

Sin embargo, no todas las aplicaciones de CNN en imagen médica tienen el objetivo de mejorar los procesos en los sistemas sanitarios, ya que también pueden utilizarse para realizar ataques informáticos cuyo objetivo sea el de evitar que se realice el diagnóstico de forma correcta. Por ejemplo, se desarrolló un método basado en redes generativas adversarias (GAN, por sus siglas en inglés) que era capaz de alterar imágenes de TC añadiendo o eliminando de forma artificial nódulos pulmonares. Se simuló la utilización de este método en rutina clínica consiguiendo alterar el diagnóstico radiológico de forma exitosa en un 99,2% de los casos cuando se introdujeron nódulos falsos en las imágenes y en un 95,8% cuando se eliminaron nódulos reales⁷.

Como conclusión, las técnicas de IA, y más concretamente las de DL han permitido el desarrollo de nuevas herramientas que mejoran los procesos del cuidado de la salud e introducen un cambio de paradigma en la evaluación de enfermedades respiratorias mediante imagen médica, automatizando procesos que en la actualidad ralentizan el flujo de trabajo hospitalario y mejorando la eficacia diagnóstica de los facultativos. No obstante, estas nuevas tecnologías también plantean diversas cuestiones éticas, como, por ejemplo, la definición de a quién se le debería atribuir la responsabilidad de un diagnóstico incorrecto cuando se utilizan tecnologías de IA para la asistencia en la toma de decisiones. Además, también es posible utilizar estos algoritmos con fines maliciosos en ataques informáticos que alteren el correcto diagnóstico de los pacientes. Por ello, estos escenarios tendrán que ser contemplados por comités multidisciplinares para implantar los sistemas de IA de forma efectiva y segura en instituciones hospitalarias con el objetivo de conseguir un sistema sanitario más eficiente y preciso que mejore la salud de las personas.

Bibliografía

1. Pasapane F, Codari M, Sardanelli F. Artificial intelligence in medical imaging: Threat or opportunity? Radiologists again at the forefront of innovation in medicine. *Eur Radiol Exp*. 2018;2:35, <http://dx.doi.org/10.1186/s41747-018-0061-6>.
2. Unreported X-rays, computed tomography (CT) and magnetic resonance imaging (MRI) scans: Results of a snapshot survey of English National Health Service (NHS) trusts. The Royal College of Radiologists [consultado 28 Nov 2019] Disponible en: https://www.rcr.ac.uk/sites/default/files/unreported_studies_feb2015.pdf.
3. Annarumma M, Withey S, Bakewell R, Pesce E, Goh V, Montana G. Automated triaging of Adult Chest Radiographs with Deep Artificial Neural Networks. *Radiology*. 2019;291:196-202, <http://dx.doi.org/10.1148/radiol.2018180921>.
4. Hwang EJ, Park S, Jin KN, Kim JI, Choi SY, Lee JH, et al., DLAD Development and Evaluation Group. Development and Validation of a Deep Learning-Based Detection Algorithm for Major Thoracic Diseases on Chest Radiographs. *Jama Netw Open*. 2019;2:e191095, <http://dx.doi.org/10.1001/jamanetworkopen.2019.1095>.
5. Youbao T, Yuxing T, Jing X, Summers R. X^L*Sor: A Robust and Accurate Lung Segmentor on Chest X-Rays Using Criss-Cross Attention and Customized Radio-realistic Abnormalities Generation. *A^r*Xⁱ*v:1904.09229*.
6. Xu M, Qi S, Yue Y, Teng Y, Xu L, Yao Y, et al. Segmentation of lung parenchyma in CT images using CNN trained with the clustering algorithm generated dataset. *Biomed Eng Online*. 2019;18:2, <http://dx.doi.org/10.1186/s12938-018-0619-9>.
7. Mirsky Y, Mahler T, Shelefi I, Elovici Y. CT-GAN: Malicious Tampering of 3D Medical Imagery using Deep Learning. *A^r*Xⁱ*v:1901.03597*.

Rafael López-González *,
José Sánchez-García y Fabio García-Castro
Área de I+D, QUIBIM, Valencia, España

* Autor para correspondencia.
Correo electrónico: rafaellopez@quibim.com (R. López-González).