

38 CONGRESO NACIONAL

seRam
Sociedad Española de Radiología Médica

 **ferm**
FUNDACIÓN ESPAÑOLA DE RADIOLOGÍA MÉDICA

VALENCIA
PALACIO DE CONGRESOS

20 - 23
MAYO 2026

www.seram2026.com

Predicción de la evolución clínica basada en *deep learning* de imágenes radiológicas

Miguel Olavarría Fernández

Hospital Universitario Sanitas La Moraleja

Presentación electrónica educativa sin
conflictos de interés.

1. Objetivo docente

Comprender cómo los modelos actuales de inteligencia artificial (IA) pueden analizar imágenes radiológicas y predecir la evolución clínica de los pacientes.

Es también de gran importancia, contextualizar estas nuevas tecnologías en nuestro entorno profesional y entender su rol como herramientas adicionales en el diagnóstico por imagen.

2. Revisión del tema

Las pruebas de imagen se utilizan diariamente para diagnosticar patologías, pero su aplicación en clínica aún tiene un gran potencial de crecimiento.

En los últimos años, los modelos de IA han evolucionado hasta poder aprender de los datos y realizar tareas para las que no han sido programadas de forma explícita. El *deep learning* es una modalidad que utiliza redes de neuronas artificiales que imitan el funcionamiento del cerebro humano y es capaz de analizar e interpretar imágenes. Ya son comunes en centros sanitarios los programas de interpretación de imágenes radiológicas asistidos por IA.

3. Más allá del diagnóstico

De la misma forma, los sistemas podrían relacionar los hallazgos directamente con diferentes pronósticos. Entrenando modelos de *deep learning* con suficientes imágenes asociadas a los resultados de cada paciente, estos pueden aprender a reconocer patrones comunes y utilizarlos para categorizar mejor la enfermedad.

4.1 Definiciones básicas

- **Inteligencia artificial (IA):** es un campo de la informática que desarrolla sistemas capaces de realizar tareas que normalmente requieren inteligencia humana, como el reconocimiento de patrones, el aprendizaje a partir de datos, la toma de decisiones o la resolución de problemas.
- **Machine learning:** es una rama de la inteligencia artificial en la que los algoritmos aprenden patrones y relaciones a partir de los datos sin estar programados mediante reglas explícitas. A partir de ejemplos previos, los modelos son capaces de generar predicciones o clasificaciones cuando se enfrentan a nuevos datos.

4.2 Definiciones básicas

- **Deep learning:** es un tipo avanzado de machine learning que utiliza redes neuronales artificiales con múltiples capas de procesamiento para analizar datos complejos. Estas redes pueden aprender representaciones jerárquicas de la información, lo que las hace especialmente eficaces en tareas como el análisis de imágenes, el reconocimiento de voz o el procesamiento del lenguaje natural.

4.3 Definiciones básicas

- **Redes neuronales convolucionales (CNN):** son modelos computacionales inspirados en la estructura y el funcionamiento de las redes neuronales biológicas. Están diseñadas para el análisis de datos con estructura espacial, como las imágenes. Utilizan operaciones matemáticas denominadas convoluciones que permiten detectar automáticamente características visuales como bordes, texturas o formas. A través de múltiples capas de procesamiento, las CNN pueden identificar patrones complejos y representaciones jerárquicas de la imagen, lo que las convierte en el modelo más utilizado en el análisis automatizado de imágenes médicas.




Figura 1. Esquema de entrenamiento de una red neuronal convolucional. Adaptado de Federico Lubinus Badillo et al., 2021.




Figura 2. CNN para reconocimiento de personas procesa la imagen en varias capas, aumentando el nivel de abstracción progresivamente. La primera capa convolucional detecta características simples como bordes y sombras, seguida de *max pooling* para reducir dimensiones. La segunda capa identifica formas más complejas como ojos, nariz y cejas, nuevamente reducidas con *pooling*. La tercera capa reconoce relaciones entre rasgos faciales, captando características distintivas del rostro. Finalmente, las capas de clasificación utilizan esta información para identificar la imagen. Adaptado de Federico Lubinus Badillo et al., 2021.

4. La información que no vemos

Las imágenes contienen más información de la que vemos. Las imágenes médicas son en realidad conjuntos complejos de datos digitales. Cada píxel o vóxel contiene información cuantificable:

- Intensidad
- Textura
- Relaciones espaciales
- Patrones de distribución

Muchos de estos patrones son demasiado sutiles o complejos para ser detectados por observación visual directa. La inteligencia artificial permite analizar estos datos de forma sistemática.




Figura 3. Se presentan los resultados de Grad-CAM aplicados a un modelo de aprendizaje profundo. En la figura se distinguen tres casos: (A) paciente sano, (B) neumonía no asociada a COVID-19 y (C) neumonía por COVID-19. Cada caso incluye tanto la radiografía de tórax como su correspondiente mapa de calor generado mediante Grad-CAM, utilizando un modelo previamente entrenado. Reproducido de Nishio M et al., 2022.

5. ¿Cómo aprende un modelo pronóstico?


Paso 1: Base de datos - Imágenes + resultado clínico asociado.

Paso 2: Entrenamiento - El modelo identifica patrones que se correlacionan con el desenlace.


Paso 3: Validación - Se corrigen sus resultados.

Paso 4: Evaluación - Se utilizan métricas como:

- AUC (Área bajo la curva ROC)
- Sensibilidad
- Especificidad
- Valor predictivo positivo/negativo



(a)



(b)

Figura 4. (a) Ejemplos del conjunto de datos de lesiones hepáticas: quiste, metástasis y hemangioma. (b) Proceso de extracción de regiones de interés (ROI) a partir de cortes de TC. Reproducido de Frid-Adar M et al. 2018.

6. ¿Cómo se puede predecir la evolución clínica?

La clave está en el modelo pronóstico que hemos entrenado. A partir de su base de datos y el algoritmo que hemos desarrollado, cuando le alimentamos nuestra imagen obtenemos una estratificación del riesgo, que aunque solo es una estimación, ya ha demostrado poder ser un factor de riesgo independiente al resto de datos clínicos.

Por ejemplo, Weiss, J. et al., 2023 encuentra que la estratificación de riesgo basada en un algoritmo de código abierto capaz de leer placas de tórax, era un factor de riesgo independiente para la mortalidad por cualquier causa pulmonar de forma estadísticamente significativa en un estudio con más de 10.000 sujetos.

7. Implicaciones médico-legales

Preguntas abiertas:

- ¿Quién es responsable si la predicción falla?
- ¿Debe el radiólogo conocer el funcionamiento del algoritmo?
- ¿Cómo documentar su uso en el informe?

Es fundamental mantener:

- Supervisión humana
- Transparencia
- Registro de decisiones

8. ¿Sustituirá al radiólogo?

NO

La IA:

- No contextualiza clínicamente como un médico
- No asume responsabilidad clínica
- No sustituye la correlación clínica

La IA bien implementada puede:

- Asistir en el diagnóstico
- Estratificar riesgo
- Reducir la variabilidad interobservador

Conclusiones:

Dentro de sus limitaciones, un modelo de predicción pronóstica adecuado podría ayudar a orientar el manejo clínico de los pacientes y optimizar el seguimiento de su enfermedad.

Las nuevas tecnologías están transformando la medicina contemporánea y no debemos pensar en la inteligencia artificial como una amenaza, sino una herramienta más para desempeñar nuestro trabajo de forma más precisa y segura.

Bibliografía:

- Badillo FL, Rueda CA, Narváez BM, Arias YE. Redes neuronales convolucionales: un modelo de deep learning en imágenes diagnósticas. Revisión de tema. *Rev Colomb Radiol*. 2021;32(1):1–10. doi:10.53903/01212095.161
- Frid-Adar M, Diamant I, Klang E, Amitai M, Goldberger J, Greenspan H. GAN-based synthetic medical image augmentation for increased CNN performance in liver lesion classification. *Neurocomputing*. 2018;321:321–31.
- Nishio M, Kobayashi D, Nishioka E, Matsuo H, Urase Y, Onoue K, et al. Deep learning model for the automatic classification of COVID-19 pneumonia, non-COVID-19 pneumonia, and the healthy: a multi-center retrospective study. *Sci Rep*. 2022;12(1):8214. doi:10.1038/s41598-022-11990-3
- Weiss, J., Raghu, V.K., Bontempi, D. et al. Deep learning to estimate lung disease mortality from chest radiographs. *Nat Commun* 14, 2797 (2023). <https://doi.org/10.1038/s41467-023-37758-5>
- LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521(7553):436-444.
- Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, Blau HM, et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*. 2017;542(7639):115-118.
- Litjens G, Kooi T, Bejnordi BE, Setio AAA, Ciompi F, Ghafoorian M, et al. A survey on deep learning in medical image analysis. *Med Image Anal*. 2017;42:60-88.
- Lambin P, Rios-Velazquez E, Leijenaar R, Carvalho S, van Stiphout RG, Granton P, et al. Radiomics: extracting more information from medical images using advanced feature analysis. *Eur J Cancer*. 2012;48(4):441-446.
- Gillies RJ, Kinahan PE, Hricak H. Radiomics: images are more than pictures, they are data. *Radiology*. 2016;278(2):563-577.
- Ardila D, Kiraly AP, Bharadwaj S, Choi B, Reicher JJ, Peng L, et al. End-to-end lung cancer screening with three-dimensional deep learning on low-dose chest computed tomography. *Nat Med*. 2019;25(6):954-961.
- Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med*. 2019;25(1):44-56.
- Pesapane F, Codari M, Sardanelli F. Artificial intelligence in medical imaging: threat or opportunity? *Eur Radiol Exp*. 2018;2:35.
- Kelly CJ, Karthikesalingam A, Suleyman M, Corrado G, King D. Key challenges for delivering clinical impact with artificial intelligence. *BMC Med*. 2019;17(1):195.
- Park SH, Han K. Methodologic guide for evaluating clinical performance and effect of artificial intelligence technology for medical diagnosis and prediction. *Radiology*. 2018;286(3):800-809.
- Collins GS, Reitsma JB, Altman DG, Moons KG. Transparent reporting of a multivariable prediction model for individual prognosis or diagnosis (TRIPOD): the TRIPOD statement. *Ann Intern Med*. 2015;162(1):55-63.
- Bluemke DA, Moy L, Bredella MA, Ertl-Wagner BB, Fowler KJ, Goh VJ, et al. Assessing radiology research on artificial intelligence: a brief guide for authors, reviewers, and readers. *Radiology*. 2020;294(3):487-489.