

Inteligencia artificial en ecocardiografía

La inteligencia artificial (IA) es una disciplina tecnicocientífica que en los últimos años ha presentado un potencial de desarrollo espectacular, produciendo una revolución similar a la que se generó en el siglo XIX con la revolución industrial. La IA invade gran parte de nuestras actividades diarias, desde las simples, como es dirigirse con *Google Maps* a nuestro trabajo diario, a las más complejas, como calcular la fracción de eyección en un estudio ecocardiográfico que se ha realizado en ese trabajo diario. Andrew Ni, uno de los científicos más conocidos del campo, tratando de expresar su futura ubicuidad, define la IA como "la electricidad del siglo XXI".

El nombre de "inteligencia artificial" fue acuñado formalmente en 1956 durante la conferencia de Dartmouth organizada por Marvin Minsky, John McCarthy y Claude Shannon, que se considera como la reunión científica que fue germen de la IA como nuevo campo científico⁽¹⁾. De una manera simple se puede definir la IA como la actividad generada por una máquina que imita las funciones intelectuales y de conocimiento que los humanos asociamos a la inteligencia humana, tales como razonar, aprender y solucionar problemas.

La ecocardiografía como método diagnóstico, sin duda, es el pilar básico de las técnicas de imagen cardíaca por su amplia difusión, tanto en el diagnóstico como en el pronóstico de la patología cardíaca. Existen muchas situaciones en las que, sin embargo, el diagnóstico, basado en la experiencia del observador y en el uso de las diferentes guías, no permite un diagnóstico razonable o simple como, por ejemplo, establecer el diagnóstico diferencial entre hipertrofia patológica o fisiológica, evaluar la positividad de una ecocardiografía de estrés o establecer el diagnóstico entre constricción o restricción, entre otros muchos. Un punto débil de esta técnica es el alto nivel de variaciones intraobservador e interobservador en las mediciones, como son la determinación de los volúmenes ventriculares y la fracción de eyección, más aún en ecocardiografías de calidad subóptima.

El uso de la inteligencia artificial en ecocardiografía y, específicamente, los métodos de *machine learning* pueden significar un aumento de las capacidades diagnósticas, así como la seguridad en la obtención de la información sobre la anatomía y función cardíaca, que puede modificar el futuro de su uso en nuestra práctica diaria.

Inteligencia artificial, *machine learning* y *deep learning*

Dentro de la IA el campo del *machine learning* recoge la capacidad de aprender de la máquina por sí misma, usando grandes conjuntos de datos, y con mínima supervisión. Por tanto, en lugar de reglas fijas escritas en código, *machine learning* permite que las computadoras aprendan por sí mismas. Un ejemplo bien conocido es el *deep-mind* de Google, que consiguió ganar al campeón del mundo de Go, aplicando técnicas de *machine learning* y entrenándose con una gran base de datos que recogía jugadas de expertos en el juego. Este tipo de aprendizaje aprovecha la potencia de cálculo de los ordenadores actuales, que pueden procesar fácilmente grandes conjuntos de datos en poco tiempo. Un ejemplo típico del uso del *machine learning* es la detección de *spam* por los ordenadores en la selección de correo electrónico. A la máquina se le proporciona una información de los correos electrónicos que se reciben por mail y se consideran *spam* y, a partir de ahí, la máquina aprende a distinguir los mismos.

Un salto importante se produce en esta última década, momento en que la máquina es capaz de aprender directamente de los datos, sin ningún tipo de supervisión humana en un proceso que se conoce como *deep learning*. Este proceso se basa en la utilización de redes neuronales cuyo diseño está basado en el cerebro humano y, más específicamente, en la utilización de las conexiones neuronales de la retina humana. Una red neuronal puede aprender de los datos, de manera que se puede entrenar para que reconozca patrones, clasifique datos y pronostique eventos futuros.

El elemento básico de la red es la neurona (que llamaremos nodo), que tal como se ve en la **Figura 1** recibe estímulos externos (I_1 y I_2), cada uno con un peso o importancia (w_1 y w_2) y los procesa en la respuesta final (*output*). El problema se complica cuando se va formando una red con varias neuronas o redes neuronales. De una manera simple, una red neuronal agrupa las neuronas en diferentes tipos de capas: capa neuronal de entrada, capas neuronales ocultas y capas de salida (**Figura 2**). Las unidades conectadas al ambiente externo se designan como unidades de entrada o capa neuronal de entrada. Existirá igualmente una capa neuronal de salida que da la respuesta del sistema. Hay otras unidades (neuronas) que simplemente están conectadas a otras neuronas del sistema y que al no tener relación directa con la información de entrada ni con la de salida del sistema, se denominan unidades ocultas.

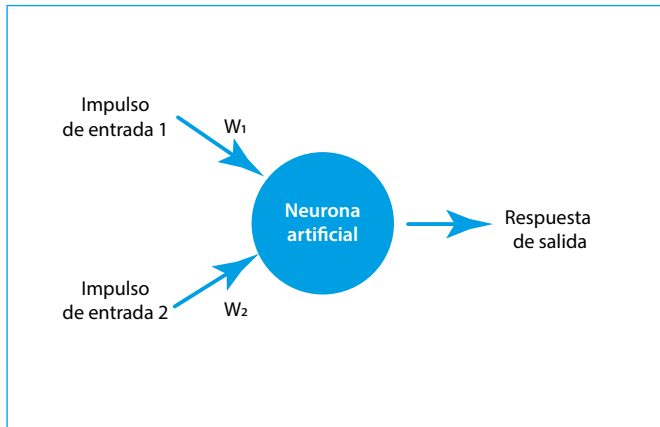


Figura 1. La neurona artificial recibe unos impulsos de entrada que la activan y produce una respuesta de salida




Figura 2. Red neuronal simple con neuronas de entrada, salida y escondidas (*hidden*)

Supongamos que se quiere hacer una red para diagnosticar el coste de una habitación de hotel. Para empezar en este caso se tendrán cuatro neuronas en la capa de entrada, cada una dedicada a una pregunta específica:

- Ciudad.
- Hotel.
- Fecha de la reserva.
- Tipo de habitación.

Las capas de entrada pasan la información a la siguiente capa o capa oculta, que realiza una serie de cálculos y los pasa a las siguientes capas. Cada conexión entre las neuronas se asocia a un peso o "importancia" del dato; en el ejemplo, al tipo de habitación se le da más peso que a la fecha de la reserva. Finalmente, la capa de salida da una predicción de precios. Si se comete un error, la máquina va haciendo pruebas de ensayo hasta ajustarse a la mejor solución. Es importante entrenar a la máquina con la introducción de datos reales para que pueda tomar referencias de la realidad.

Existen tres tipos diferentes de redes neuronales, cada una con un tipo diferente de aplicación:

- **Red neuronal profunda.** Se utiliza básicamente en el tratamiento de texto.
- **Red neuronal recurrente.** Se utiliza en el análisis de datos secuenciales, por ejemplo, el valor de la acción de una empresa que va a depender del valor del día anterior.
- **Red neuronal convolucional.** Son las más utilizadas en el tratamiento de imagen.

Redes neuronales convolucionales

Este tipo de red neuronal se utiliza básicamente para poder procesar imágenes de vídeo de una manera eficiente: supongamos una imagen de un sector ecográfico de 300 píxeles por 300 píxeles con los tres colores básicos: rojo, verde y azul. Si se utiliza una red neuronal estándar, para tener toda la información de cada imagen se deberá tener más de 9.000.000 millones neuronas iniciales ($300 \times 300 \times 3$) antes de pasar a la capa siguiente, lo que implica una capacidad de conexiones entre capas extremadamente compleja de manejar. Con las redes neuronales convolucionales se simplifica la imagen inicial usando una serie de filtros por toda la imagen. Una vez que la máquina define un algoritmo de cálculo es necesario un paso muy importante que es el testing para probar y rectificar el algoritmo automáticamente.

Inteligencia artificial en imagen cardíaca: el ejemplo de la ecocardiografía

La ecocardiografía es sin duda la técnica diagnóstica más utilizada en el campo de la cardiología. La aplicación de la inteligencia artificial viene a completar algunas de sus limitaciones y abre campos a un uso más eficiente de la técnica.

Identificación y reconocimiento de las vistas ecocardiográficas

Sin duda el punto de partida para una valoración y análisis de la ecocardiografía con inteligencia artificial es enseñarle a reconocer en qué vista ecocardiográfica se está trabajando, así como el método de estudio, modo M, Doppler o ecocardiografía estándar. Kamis⁽²⁾ confirma cómo utilizando algoritmos de machine learning se pueden reconocer con exactitud el 95% de los cortes obtenidos por vía apical. En el mismo sentido, Madani⁽³⁾ ha demostrado recientemente cómo utilizando redes convolucionales neurales y deep learning es posible entrenar a la red neuronal para que identifique y clasifique 15 cortes diferentes con una seguridad cercana al 98% (Figura 3).

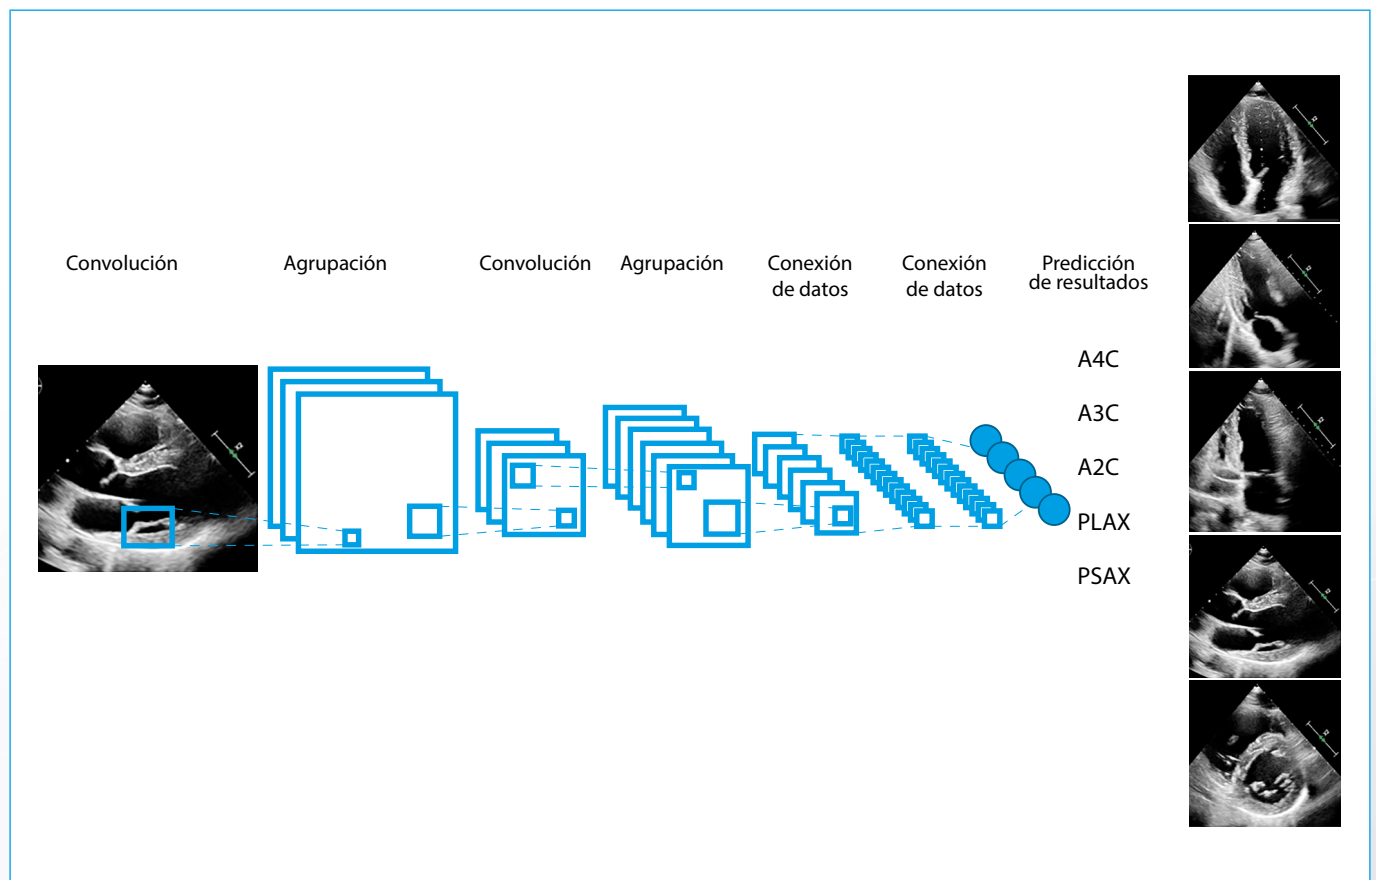


Figura 3. Uso de redes neuronales convolucionales para identificar los distintos planos ecocardiográficos. Cada convolución implica la aplicación de un filtro que va reduciendo y simplificando la información a utilizar

Sin duda esta detección por la máquina de la sección ecocardiográfica estudiada era un paso fundamental para el uso de la IA en ecocardiografía y que el experto en ecocardiografía realiza con su experiencia de una manera totalmente automática e intuitiva.

Medición de parámetros cuantitativos

Uno de los puntos más importantes de la interpretación ecocardiográfica es la cuantificación de las medidas, que va a ser básica en la toma de decisiones. Un ejemplo clásico es la determinación de los volúmenes y la fracción de eyección con ecocardiografía tanto del ventrículo derecho como del izquierdo.

Utilizando algoritmos de árbol de decisiones (*random forest*), el grupo de Chicago de R Lang^(4,5) ha demostrado la capacidad para obtener con precisión los bordes endocárdicos y, por tanto, los volúmenes de las cavidades con valores comparables a *gold standard* de la resonancia magnética. En este sentido todo el desarrollo del heart model iniciado por este grupo de trabajo ha sido realmente la primera introducción de la IA en los equipos ecocardiográficos para su uso práctico en la práctica diaria.

La automatización de las medidas no sólo va a conseguir una mayor reproducibilidad de las mismas, sino también acercar las precisiones de cálculo entre el experto y aquel que se inicia en la técnica, lo que sin duda significa un aumento en la seguridad diagnóstica de la ecocardiografía y, más aún, cuando la ecocardiografía se maneja cada vez más por profesionales no cardiólogos especialistas expertos. Por otra parte, se han creado algoritmos prácticamente automáticos que permiten la medición de parámetros complejos como con el cálculo automático del PISA tridimensional⁽⁶⁾, la medida tridimensional de la válvula mitral⁽⁷⁾ o el reconocimiento de la raíz aórtica y la válvula aórtica en el espacio⁽⁸⁾ que, de nuevo, consiguen más precisión en las mediciones y una mayor velocidad de cálculo.

Diagnósticos definitivos globales con inteligencia artificial

Sin duda, el interés final de estas técnicas es poder establecer un diagnóstico definitivo en diferentes situaciones en que es de difícil realización porque necesita una gran experiencia por parte del que lo realiza. Un ejemplo típico es la distinción entre hipertrofia fisiológica o patológica del atleta, donde se ha propuesto que el uso de IA con redes neuronales artificiales y árbol de decisiones (random forest) sea capaz de establecer el diagnóstico diferencial entre estas dos situaciones con una sensibilidad superior al 95%⁽⁹⁾.

Recientemente Omar⁽¹⁰⁾ ha demostrado que las redes convolucionales neurales se pueden utilizar para aumentar la seguridad diagnóstica de la ecocardiografía de estrés que, como es bien conocido, en muchas ocasiones es una prueba con un análisis muy subjetivo, que precisa un alto grado de experiencia. Tras analizar diferentes modelos, como *random forest*, *deep learning* y *support vector machines*, las redes convolucionales neurales ofrecen un modelo con una gran sensibilidad (81%) cuando se establece la comparación con el lector experto y abren un gran campo a su utilización para la toma de decisiones en base al estudio de ecocardiografía de estrés.

Sengupta⁽¹¹⁾ ha demostrado recientemente la utilidad de un algoritmo de machine learning para establecer uno de los diagnósticos más complejos en ecocardiografía, como es la distinción entre pericarditis constrictiva y miocardiopatía restrictiva con una seguridad diagnóstica del 90%. Igualmente, Zhang⁽¹²⁾ hace un entrenamiento de redes convolucionales neurales con datos de cerca de 14.000 ecocardiografías y demuestra que el algoritmo es preciso en el diagnóstico de la hipertensión arterial pulmonar, la amiloidosis y la miocardiopatía hipertrófica. Cada día se van incorporando con rapidez nuevos trabajos que confirman la utilidad del método en nuevos escenarios clínicos que van ampliando su uso en la práctica diaria.

Hacia dónde vamos con la utilización de la inteligencia artificial en la interpretación ecocardiográfica

Cuando se habla de IA específicamente en técnicas de imagen diagnóstica siempre surge la pregunta de si los expertos en imagen son una "raza" médica a extinguir ante la interrupción de máquinas que diagnostican con más precisión que ellos. Sin duda, la manera de trabajar en nuestro medio se va a modificar en función de la incorporación de la IA en la rutina diaria. Hay que pensar que se está en los albores del método, algo así como el modo M de la IA y que el campo de desarrollo es inmenso, pero creo que no hay que preocuparse por la posibilidad de verse desplazado, todo lo contrario, se debe dar la bienvenida a esta herramienta que va a ayudar al cerebro humano a ser más efectivo. Hay que recordar que el cerebro humano tiene unas capacidades innatas de abstracción, razonamiento, sentido común e integración del conocimiento: una de las grandes virtudes de la asociación de nuestros billones de neuronas es establecer patrones jerárquicos de conocimiento basado en nuestra experiencia previa, que son imposibles de ni siquiera insinuarse con la simplicidad de las redes neuronales artificiales que maneja un ordenador.

Crear que las máquinas que el hombre crea van a sustituirnos es tener poca confianza en los cerebros que las han creado. Todo lo contrario, las máquinas nos ayudarán en labores que complican nuestra rutina, como otras máquinas nos han liberado de trabajos tediosos (desde la lavadora hasta las máquinas recolectoras del campo).

Estas máquinas nos harán más efectivos, con más capacidad de resolución, con eliminación de cálculos tediosos y tiempo malgastado, con exactitud en las mediciones que igualarán al experto y no experto en su obtención. Nos darán más tiempo para comunicarnos con el paciente como centro de nuestra profesión. Estamos en la infancia del método y deberemos esperar a que los refinamientos en su uso definan su sitio en la clínica diaria, aunque sus primeros balbuceos prometen un porvenir espectacular.

Miguel Ángel García Fernández*
Antonio López Farré**

* Cátedra de Imagen cardíaca. Universidad Complutense de Madrid. Madrid. España

** Profesor Titular, Departamento de Medicina, Facultad de Medicina, Universidad Complutense de Madrid.
Académico Correspondiente de la Real Academia Nacional de Medicina de España

Referencias:

1. Kaplan A, Haenlein M, Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence, *Business Horizons* 2019; 62 (1): 15-25.
2. Khamis H, Zurakhov G, Azar V, *et al.* Automatic apical view classification of echocardiograms using a discriminative learning dictionary. *Medical Image Analysis* 2017; 36: 15-21.
3. Madani A, Arnaout R, Mofrad M, Arnaout R. Fast and accurate view classification of echocardiograms using deep learning. *NPJ Digit Med* 2018; 6: 1-8.
4. Otani K, Nakazono A, Salgo IS, *et al.* Three-dimensional echocardiographic assessment of left heart chamber size and function with fully automated quantification software in patients with atrial fibrillation. *J Am Soc Echocardiogr* 2016; 29: 955-965.
5. Tamborini G, Piazzese C, Lang RM, *et al.* Feasibility and accuracy of automated software for transthoracic three-dimensional left ventricular volume and function analysis: comparisons with two-dimensional echocardiography, three-dimensional transthoracic manual method, and cardiac magnetic resonance imaging. *J Am Soc Echocardiogr* 2017; 30: 1049-1058.
6. De Agustin JA, Marcos-Alberca P, Fernandez-Golfin C, *et al.* Direct measurement of proximal isovelocity surface area by single-beat three-dimensional color Doppler echocardiography in mitral regurgitation: a validation study. *J Am Soc Echocardiogr* 2012; 25: 815-823.
7. Kagiya N, Toki M, Hara M, *et al.* Efficacy and accuracy of novel automated mitral valve quantification: three-dimensional transesophageal echocardiographic study. *Echocardiography* 2016; 33: 756-763.
8. Calleja A, Thavendiranathan P, Ionasec RI, *et al.* Automated quantitative 3-dimensional modeling of the aortic valve and root by 3-dimensional transesophageal echocardiography in normals, aortic regurgitation, and aortic stenosis: comparison to computed tomography in normals and clinical implications. *Circ Cardiovasc Imaging* 2013; 6: 99-108.
9. Narula S, Shameer K, Salem Omar AM, *et al.* Machine-learning algorithms to automate morphological and functional assessments in 2D echocardiography. *Journal of the American College of Cardiology* 2016; 68: 2287-2295.
10. Omar HA, Domingos JS, Patra A, *et al.* Quantification of cardiac bull's-eye map based on principal strain analysis for myocardial wall motion assessment in stress echocardiography. In: 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018), 2018.
11. Sengupta PP, Huang YM, Bansal M, *et al.* Cognitive Machine-Learning Algorithm for Cardiac Imaging: A Pilot Study for Differentiating Constrictive Pericarditis From Restrictive Cardiomyopathy. *Circ Cardiovasc Imaging* 2016; 9(6): pii: e004330
12. Zhang J, Gajjala S, Agrawal P, *et al.* Fully automated echocardiogram interpretation in clinical practice: feasibility and diagnostic accuracy. *Circulation* 2018; 138: 1623-1635.