



¿Eres Residente De Radiología? Esto Es Lo Primero Que Debes Saber Sobre Inteligencia Artificial

Alberto Ramírez García-Mina¹,
Andoni Azcona Pereda²,
Carmen Mbongo Habimana³,
Patricia Oliveros Ordás¹

¹Hospital Universitario Puerta de Hierro, Majadahonda

²Hospital Universitario 12 de Octubre; Madrid

³Clínica Universidad de Navarra; Navarra

Contacto: albert_unit96@hotmail.com



OBJETIVO DOCENTE

El objetivo de este trabajo es revisar los conceptos más básicos sobre **Inteligencia Artificial (IA)** en el ámbito de la Radiología para poder sintetizar lo primero que debería saber quien empieza a adentrarse en el mundo del *Machine Learning*.

Se revisarán:

- Definiciones de los **conceptos fundamentales**.
- **Aplicaciones clínicas** de la IA en Radiología.
- **Debilidades**, amenazas e inconvenientes de la IA.
- Qué nos depara en el **futuro**.

REVISIÓN DEL TEMA

Introducción

Lleva tiempo hablándose de la **Inteligencia Artificial (IA)** en el ámbito sanitario. Incluso hay quien duda de escoger la especialidad de Radiología por miedo a que el aprendizaje de una máquina nos sustituya en el futuro. Llegados a este punto, parece inevitable que todos los radiólogos, tanto los que llevan ya tiempo formándose como los que empiezan ahora, aborden este tema con los ojos del curioso. Con ilusión por el futuro.

De todas las aplicaciones que utilizan IA en el ámbito de la Medicina, una gran parte de ellas se centra específicamente en la Radiología [1]. Se trata de una de las especialidades con mayor contacto con la IA en el momento actual. Además, hay un interés sobre este tema que crece exponencialmente. Si se introduce en motores de búsqueda como *PubMed* “Artificial Intelligence AND Radiology” o “Deep Learning AND Medical Imaging”, y se filtran los resultados por año, se observa un crecimiento exponencial en el número de publicaciones desde 2010 hasta 2021 (*Figura 1*).

La integración de la IA en la Radiología ya es una realidad, que seguirá creciendo rápidamente. Entender mejor su fundamento será de gran ayuda en el presente y en el futuro para todo radiólogo.

Figura 1

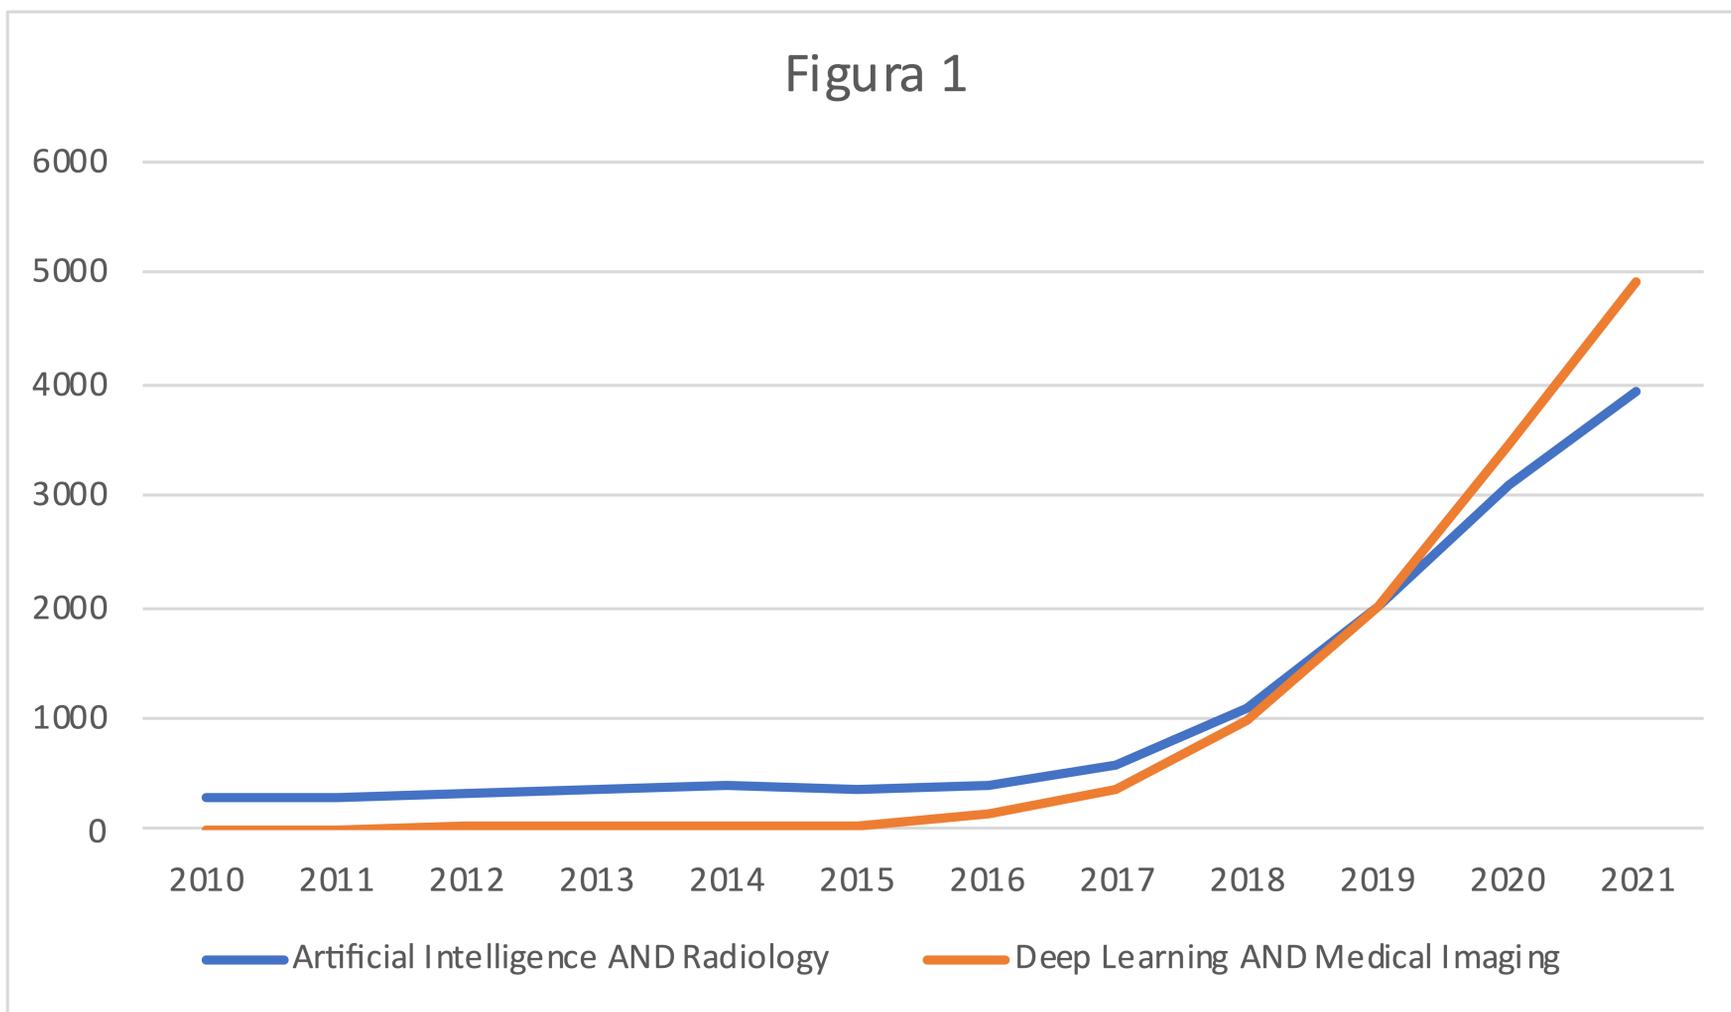


Figura 1. Resultados de publicaciones sobre IA y Radiología en PubMed en los últimos años.

Conceptos básicos

La IA se fundamenta en disciplinas con las que un profesional de la salud no está tan familiarizado. Por este motivo, puede llegar a ser confuso no tener una idea básica de los conceptos más importantes cuando se revisa bibliografía sobre IA y Radiología. A continuación, se definen los pilares de la IA de la manera más sencilla posible [2,3]. Nótese que primero se definirán los conceptos más amplios, como IA, para después adentrarse en conceptos más específicos, que están englobados en los anteriores, tal y como se representa en la *Figura 2*.

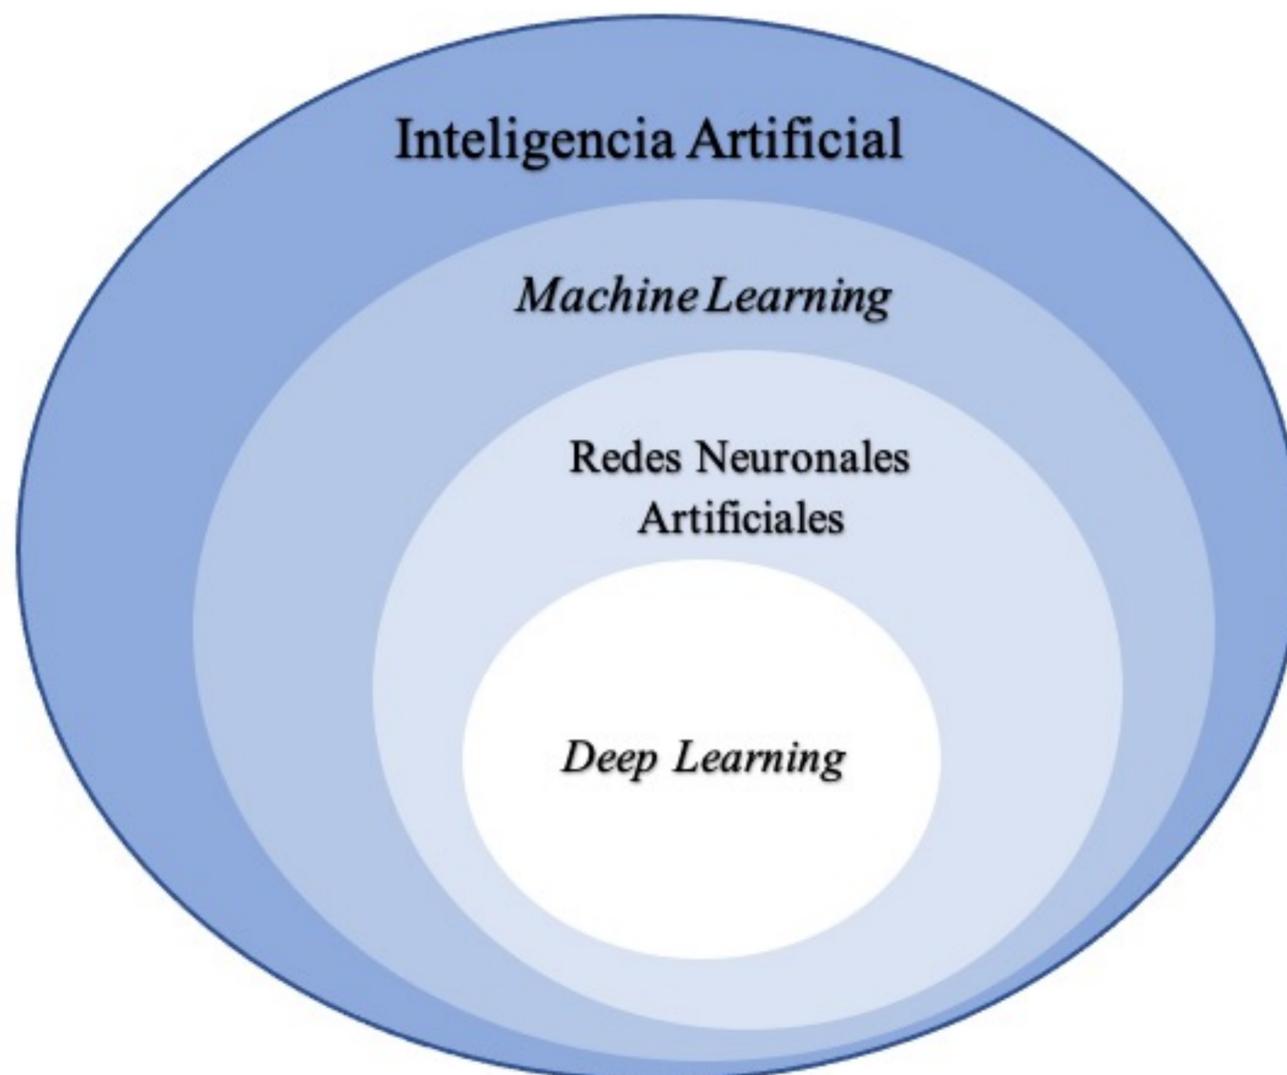


Figura 2. Relación entre los conceptos básicos de la IA.

- **Inteligencia Artificial (IA):** habilidad de las máquinas de llevar a cabo tareas que sean consideradas por los humanos como inteligentes. Por tanto, es un concepto amplio y que adquiere distintos matices conforme va avanzando la humanidad.
- **Algoritmo:** no es más que el conjunto ordenado de los pasos de una secuencia lógica que permite solucionar un problema. Es un término muy empleado en el ámbito de la IA.
- **Machine Learning (ML):** campo de la IA en el que las máquinas aprenden automáticamente a partir de la acumulación de datos. En función del grado de ayuda que se recibe en este proceso de aprendizaje, se habla de diferentes términos (supervisado, no supervisado, semi-supervisado, refuerzo positivo o negativo... *Tabla 1*).

Aprendizaje no supervisado	Aprendizaje supervisado	Aprendizaje semi-supervisado	Aprendizaje por refuerzo
No se proporciona <i>feedback</i> o soluciones a los problemas. Es decir, el <i>input</i> lo forman datos no etiquetados .	Se ayuda al modelo de aprendizaje ya que parte de datos etiquetados , de forma que ya conoce el <i>output</i> que se debe alcanzar.	Es una mezcla entre los dos anteriores. Se aportan menos etiquetas explicando el <i>output</i> que en el modelo supervisado.	Se ayuda a la IA con un sistema de refuerzos positivos (recompensas) o negativos (castigos).

Tabla 1. Los diferentes modelos de aprendizaje de *Machine Learning*. El modelo supervisado se utiliza generalmente para resolver problemas de clasificación o realizar predicciones, mientras que el modelo no supervisado suele utilizarse para establecer patrones o relaciones entre conjuntos de datos.

- **Redes Neuronales Artificiales y *Deep Learning* (DL):** *Deep Learning* es un subtipo de *Machine Learning*. La importancia de este concepto reside en que es la base de la mayoría de los avances de la IA en el ámbito de interpretación de imagen. Quiere decir que los algoritmos se organizan en distintas capas conectadas de forma jerárquica. Es una idea inspirada en el complejo funcionamiento de las neuronas del cerebro humano. Las múltiples capas de algoritmos funcionan como Redes Neuronales Artificiales (*Artificial Neural Networks*). Por eso, existe un concepto más general que describe este modo de funcionamiento, las Redes Neuronales Artificiales, y otro concepto más específico para referirse a estas redes neuronales artificiales cuando adquieren un alto grado de complejidad con múltiples capas, el *Deep Learning* (*Figura 3.1 y 3.2*).
- **Procesamiento de Lenguaje Natural (*Natural Language Processing*):** campo de la IA que se centra en comprender y clasificar las palabras y frases de los textos de manera estructurada. Adquiere importancia en la creación de informes radiológicos.
- **Radiómica (*Radiomics*):** hace referencia a la utilización de gran cantidad de información cuantitativa de las imágenes de extensas bases de datos, pudiendo así establecer relaciones que el ojo humano por sí solo no podría establecer. Es de gran utilidad a la hora de tomar decisiones, como por ejemplo si un determinado tratamiento oncológico está funcionando o no.

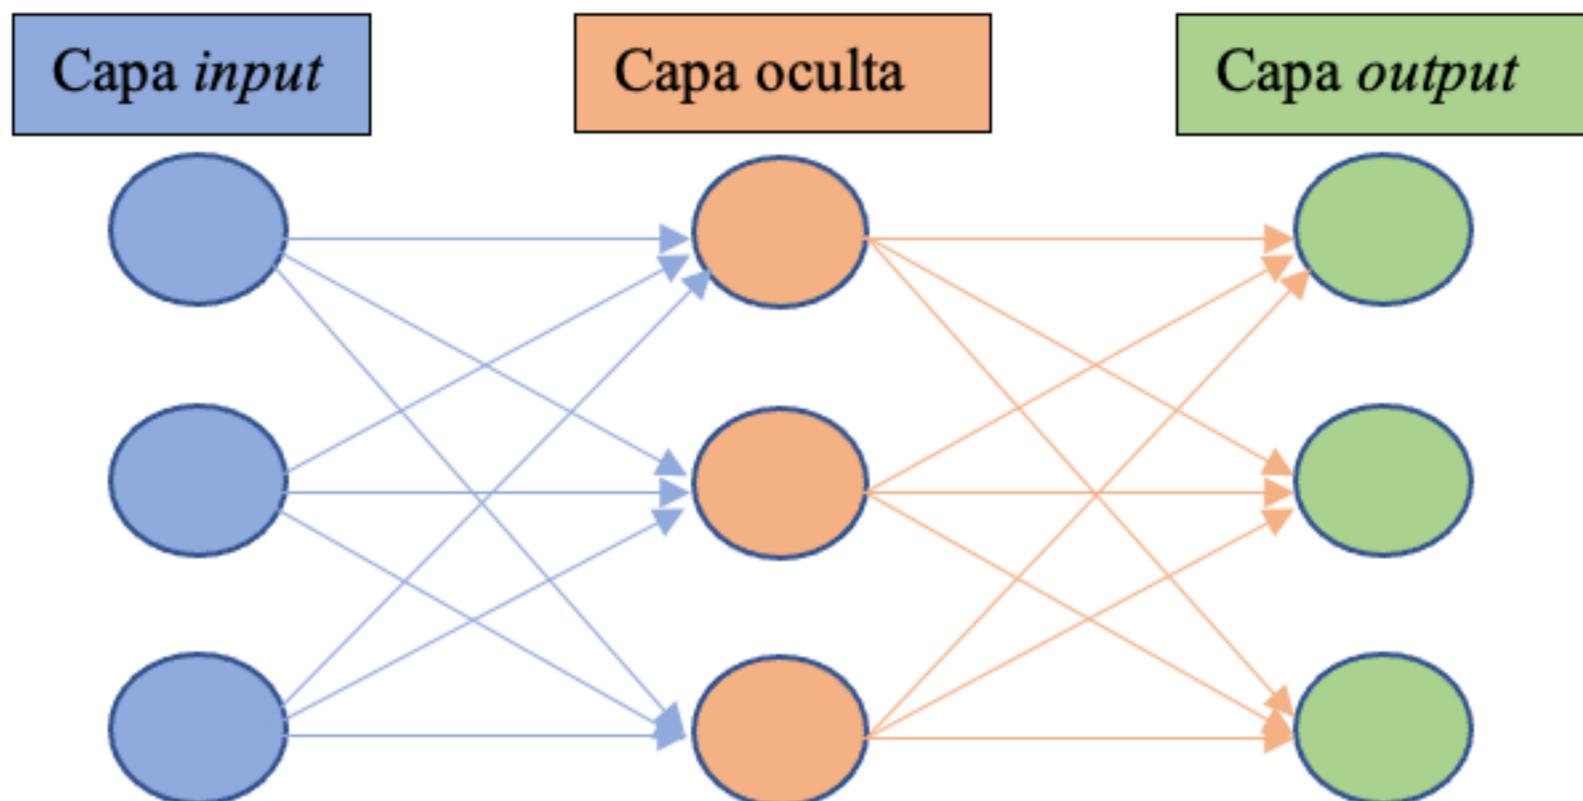


Figura 3.1 (ver continuación).

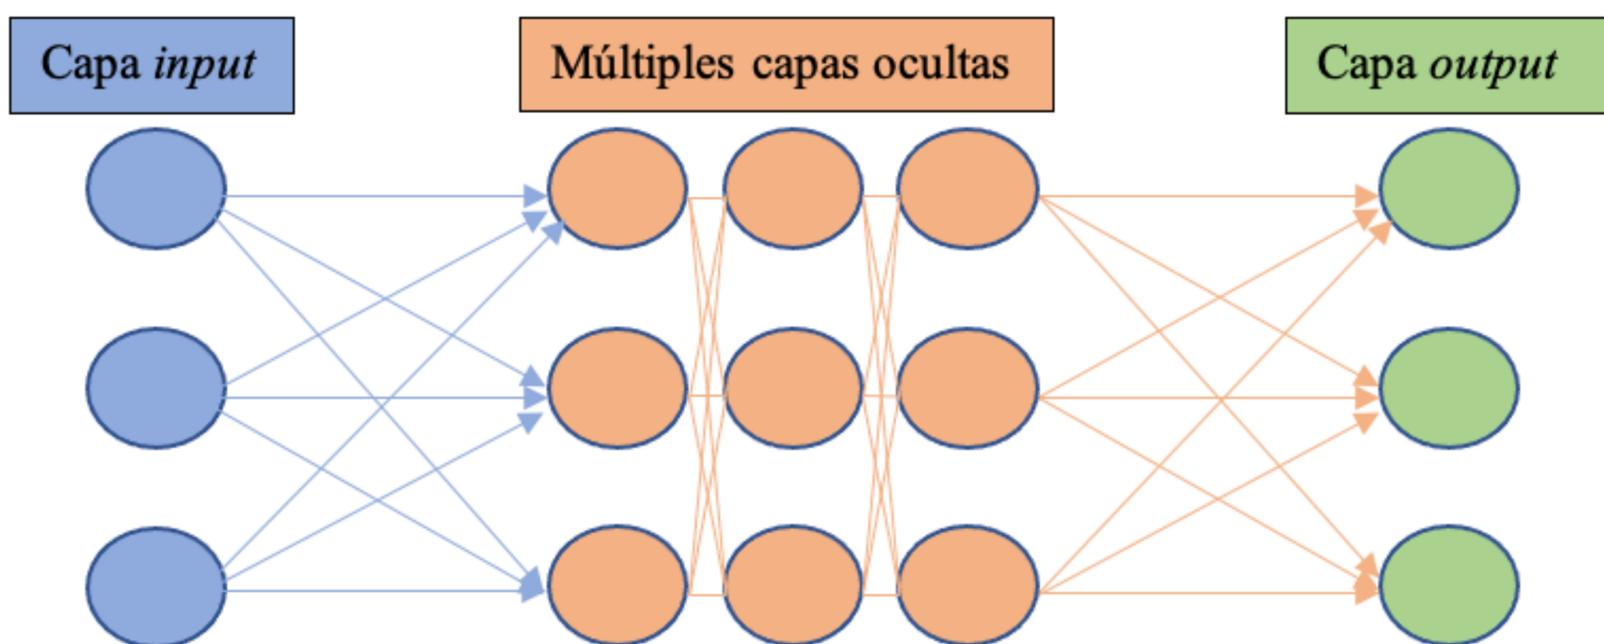


Figura 3.2 (ver continuación).

Continuación. Se representa esquemáticamente el funcionamiento y la diferencia entre Redes Neuronales Artificiales y *Deep Learning*. Toda la información con la que trabajará el sistema de IA se denomina *input*. El resultado del trabajo de la IA será el *output*. Estas dos capas son las únicas que pueden conocerse. Por eso las “neuronas” que procesan el *input* para obtener el *output* o resultado son la capa “oculta”. Nótese que cuando hay múltiples capas jerarquizadas de redes neuronales artificiales se habla de *Deep Learning*.

Aplicaciones clínicas de la IA en Radiología

Una vez desarrollados los conceptos básicos acerca de la IA, se debe conocer cómo va a modificar la práctica clínica del radiólogo. Lo más importante es que la IA no sólo participa en la interpretación de la imagen sino en todo el flujo de trabajo del radiólogo, desde la organización de las peticiones hasta una mejor redacción del informe [4]. En este apartado, se explicarán dichas funciones aportando a su vez ejemplos en cada paso del flujo de trabajo (*Figura 4*).

Peticiones

En primer lugar, se debe considerar que hay pacientes que no acuden a una cita programada perdiendo así la oportunidad de un diagnóstico más temprano. Varios estudios apuntan a una serie de variables independientes como predictores de estas faltas, tales como la raza, o el estatus socioeconómico [5]. Mediante la creación de algoritmos que tienen en cuenta todos estos factores se puede predecir el riesgo de cada paciente de faltar a su cita y realizar un seguimiento más estrecho de aquellos con un riesgo alto, mediante, por ejemplo, llamadas telefónicas que le recuerden su cita. Para ello, el médico peticionario sólo debe introducir sus datos y el algoritmo calcularía el riesgo basándose en parámetros estadísticos obtenidos en la lite-



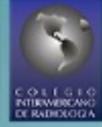
ratura.

En segundo lugar, puede ayudar al médico peticionario a elegir la prueba más adecuada para el paciente. De nuevo, un algoritmo que dispone de las guías de recomendación de pruebas podría seleccionar la prueba que mejor se ajuste a cada paciente. Asimismo, permitiría detectar alergias a contraste, lo que ahorraría reacciones adversas no deseadas.

Adquisición de la imagen

El mayor desarrollo en este aspecto se ha vivido en la pandemia de COVID-19 en la que ha resultado imprescindible tener el menor contacto posible con el paciente para evitar contagios del personal sanitario. Convencionalmente, el técnico debía entrar en la sala para garantizar una posición adecuada del paciente y saber qué rango del cuerpo debía cubrir. Con un algoritmo de *Machine Learning*, al que previamente se le ha introducido una base de datos de suficiente envergadura, supervisado además por el técnico, se podría automatizar este proceso mediante la colocación de sensores en la sala del TC que detectan si la posición del paciente es la correcta, como se ha introducido en algunos hospitales chinos [6]. Este proceso se puede generalizar a cualquier prueba y parte anatómica del cuerpo. Así, por ejemplo, si se desea realizar una TC craneal sin contraste, los sensores podrían detectar si el paciente mantiene la cabeza demasiado flexionada o extendida y garantizar una posición adecuada avisando al técnico que se encuentra en otra sala; después, seleccionarían el rango anatómico desde el vertex craneal hasta C2 pudiendo reconocer estas estructuras gracias al análisis previo de otros pacientes. El proceso se agilizaría con el tiempo dado que la IA aumenta su velocidad a medida que los datos se incrementan.

Otra utilidad de la IA en este aspecto es el aumento de la velocidad de la RM. Estas técnicas se basan en algoritmos de *Deep Learning* supervisados. De esta manera, primero se produce una imagen con baja resolución que



tarda poco en obtenerse y la IA mejora su calidad hasta convertirla en una prueba apta gracias a la consistencia con otras imágenes guardadas en una base de datos.

Por último, la IA permite mejorar las reconstrucciones en 3D mediante algoritmos de *Deep Learning*. Actualmente hay dos técnicas comercializadas para realizar reconstrucciones y ambas se basan en entrenar al algoritmo con imágenes de alta calidad de manera que su labor es imitarlas con la reconstrucción que se desea realizar, empleando la menor dosis de radiación posible y ahorrando además tiempo [7].

Diagnóstico

La primera aplicación en este apartado, y probablemente la más conocida, es la detección automática de hallazgos. Para este propósito existe el término *use case*, que describe situaciones específicas en las que la IA tiene utilidad. La **detección guiada por ordenador (CAD, *Computer Aided Diagnosis*)** aúna a todas aquellas aplicaciones desarrolladas para cada *use case*. La característica fundamental de estas aplicaciones es que sólo detectan aquello para lo que han sido específicamente programadas y su rendimiento se basa en trabajar con grandes bases de datos. Algunos ejemplos son:

- Detección de neumotórax: esta aplicación rastrea las radiografías de tórax realizadas y envía una alerta al radiólogo si encuentra signos compatibles con neumotórax, de manera que éste pueda priorizar dicho estudio y revisarlo antes. Hoy en día ya se han desarrollado aplicaciones aprobadas para este fin.
- Detección de derrame pleural: esta aplicación funciona de un modo similar a la anterior.
- Detección de cáncer de mama, pulmonar y prostático: Una de las ventajas de estas aplicaciones es que el diagnóstico podría no verse influenciado por factores que sí afectan al ojo humano, como la densidad de la mama [8].



Otro uso de la IA es la **segmentación**. Consiste en dividir una imagen digital en varias regiones (grupos de píxeles) denominadas segmentos. Más concretamente, la segmentación es un proceso de clasificación por píxel que asigna una categoría a cada píxel de la imagen analizada. De esta manera, los píxeles que presenten la misma categoría se agruparán dentro del mismo segmento. Esto permite a la IA la caracterización de órganos, fluidos y lesiones. Por ejemplo, existen aplicaciones que permiten la segmentación del ventrículo izquierdo para calcular la fracción de eyección o el volumen ventricular. Otro ejemplo sería la cuantificación del enfisema pulmonar en TC.

Aplicaciones que seguirán desarrollándose y cobrarán más importancia en el futuro

- **Radiómica:** se ha definido previamente en el apartado “Conceptos básicos”. Lo interesante es la importancia que va a tener en el futuro gracias a la capacidad de elaborar patrones. Las aplicaciones de la radiómica podrían ser la predicción de la respuesta al tratamiento, el estadiaje tumoral y la identificación de tejidos.
- **Bancos de imágenes:** instruyendo a la IA, se puede conseguir que reconozca elementos comunes en imágenes y guarde las que los presenten. De esta manera, se podrían estudiar enfermedades y descubrir patrones acerca de su evolución o respuesta al tratamiento, lo que serviría de base para la publicación de estudios.
- **Producción de informes:** parece lógico asumir que, si la IA ayuda a la identificación e interpretación de imágenes, también pueda hacerlo en la redacción de informes de dichas imágenes. En este sentido, la RSNA, con la colaboración de la ESR, ha desarrollado unos informes estándar para describir ciertas patologías y así conseguir homogeneidad entre instituciones y países [2]. La IA podría intervenir aquí mediante la unión automática de los hallazgos con el informe que les corresponde.

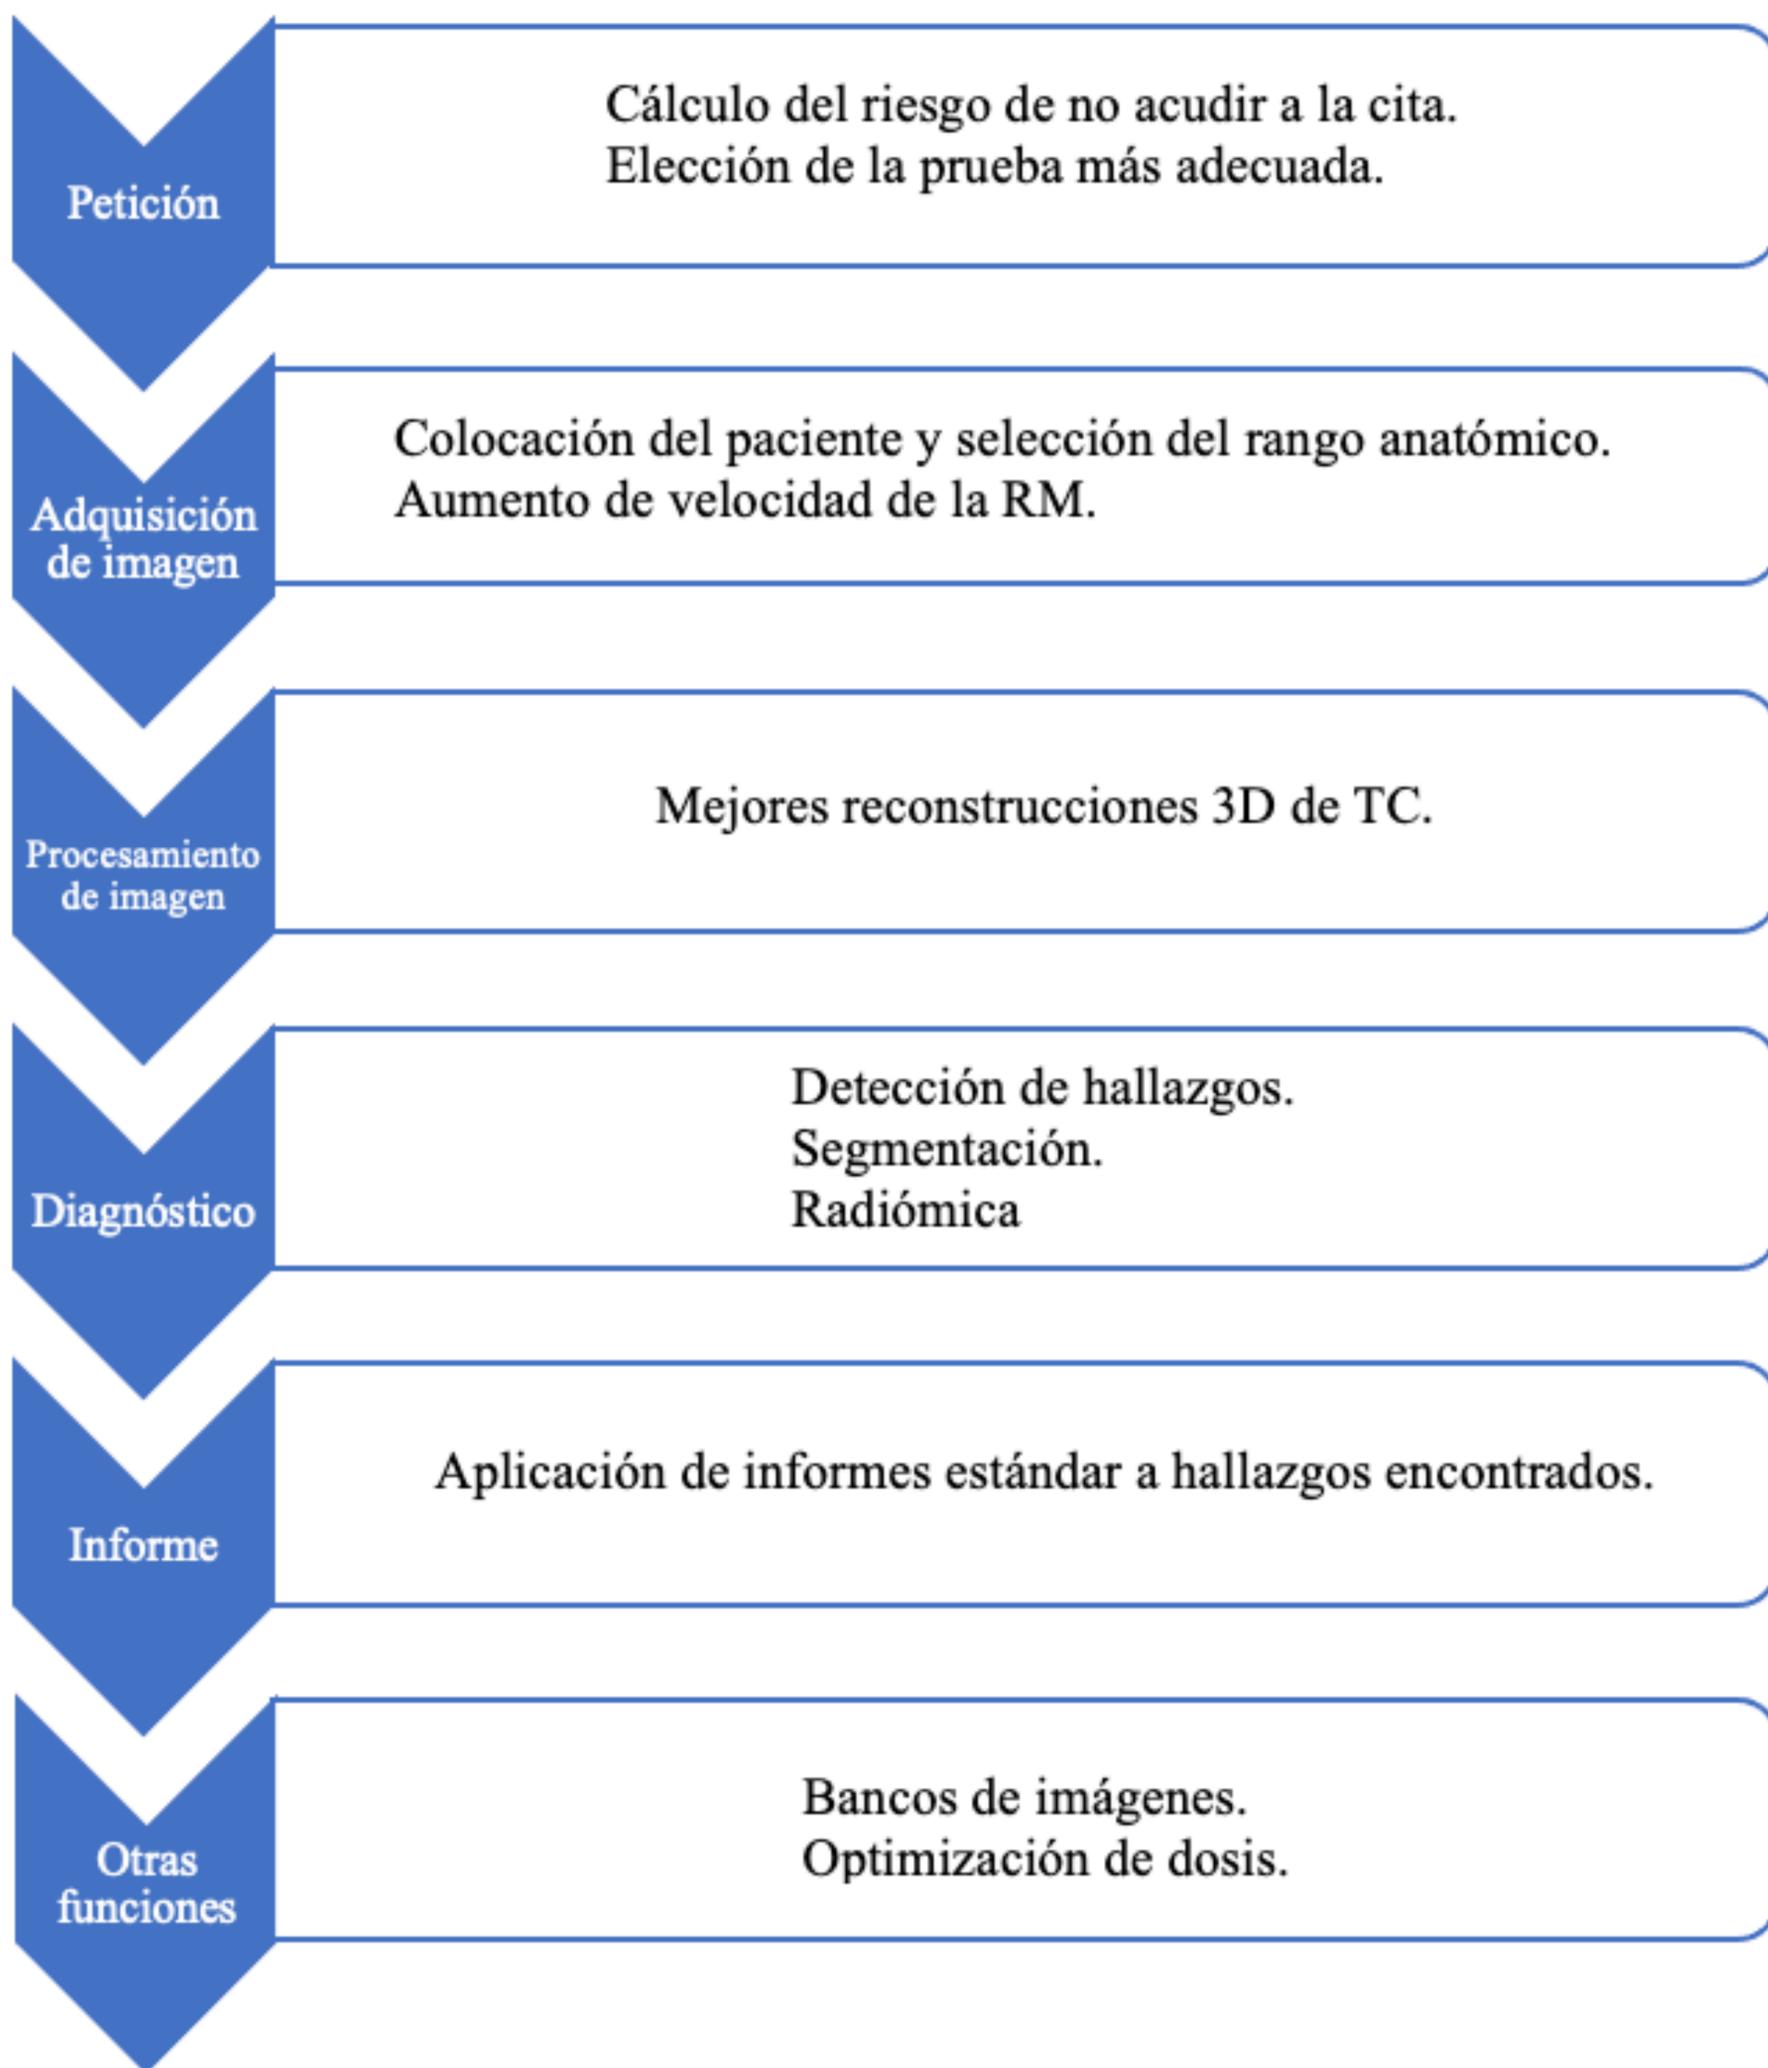


Figura 4. Flujo de trabajo del radiólogo y aplicaciones de la IA en cada etapa.



Debilidades, amenazas e inconvenientes de la IA

Si bien es cierto que son muchas las ventajas que ofrecen las diversas aplicaciones de la Inteligencia Artificial, conviene no perder de vista que su uso también plantea ciertos inconvenientes. En este sentido, interesa recalcar que el gran impacto que la IA está teniendo en las dinámicas de trabajo de los radiólogos -y por ende en los pacientes- debe ser enfocado hacia el bien y no lo contrario. A continuación, repasaremos algunos de los problemas logísticos, éticos y legales planteados durante los últimos años (Tabla 2).

Gran inversión

Por un lado, hay que saber que los sistemas de ML e IA realizan predicciones y establecen diagnósticos en base a una ingente cantidad de datos previamente almacenados en el sistema. Esto requiere un arduo proceso de entrenamiento del software (el algoritmo) que ha de ser realizado con antelación, algo que supone una importante inversión de tiempo y recursos humanos y económicos. Este proceso de entrenamiento podría ser obviado en algunas situaciones, como sería el caso de los algoritmos de IA no supervisados: en éstos, no hay evaluación de las pruebas de imagen por parte de un radiólogo una vez establecido el diagnóstico por parte de la máquina. Esto reduce en cierta medida la carga de trabajo y dinero, algo que necesariamente se traduce a largo plazo en peores resultados diagnósticos con respecto a los algoritmos supervisados [2].

Overfitting y dificultades para generalizar

Otro de los problemas planteados en el uso de sistemas de IA es el conocido fenómeno del *overfitting* -así como su versión opuesta, el *underfitting*-, que hace referencia a la información proporcionada por el algoritmo que da lugar a eventos de salud irrelevantes o incorrectos por una mala interpretación del ruido aleatorio o de determinados hallazgos infrecuentes. De modo que el modelo va aprendiendo en un entorno de entrenamiento en el que necesariamente va memorizando -junto a los datos relevantes- ruido irrelevante y, como consecuencia, genera errores en la interpretación de las imágenes [2,9].

Se han propuesto diferentes soluciones a ello, como por ejemplo el uso de sucesivas rondas de entrenamiento en diferentes entornos de datos para así ir mejorando progresivamente la precisión y generalizabilidad del algoritmo antes de su autorización para el uso general [2,10].



Aspectos éticos

Por lo que respecta a los aspectos éticos suscitados por el uso de los sistemas de IA, es fácil deducir que existe una cierta falta de transparencia en el modo de obtención de los resultados diagnósticos ofrecidos por los algoritmos. Es difícil conocer qué sucede en los múltiples pasos escondidos (las “capas ocultas”) que se realizan hasta que el sistema genera un diagnóstico. Este desconocimiento (**cajas negras o *black box***) impide un adecuado trazado de los pasos necesarios en el sistema para proporcionar un diagnóstico específico. Por ejemplo, en lo que se refiere a la situación financiera del paciente, ¿podría el algoritmo tener en cuenta los datos económicos del paciente a la hora de proponer un tratamiento u otro [10]?

Aspectos legales

Con relación a la situación legal de estos sistemas, es importante tener en cuenta que en el momento en el que empiezan a tomar decisiones de forma autónoma y dejan de ser una herramienta de soporte, se crean problemas difíciles de gestionar. Por ejemplo, en el caso de darse un error médico, no está bien establecido en quién recaería la responsabilidad legal: si en la institución hospitalaria o bien en las empresas productoras de software de IA y sus distribuidores [1].

Junto a esto, el uso de softwares de IA aplicados al ámbito de la salud tiene que estar sujeto a los mismos estándares de regulación que cualquier otro dispositivo o producto médico aprobado por la FDA o por la Regulación Europea de Dispositivos Médicos. Sólo aplicando los mismos estrictos estándares de responsabilidad, efectividad y validación de uso clínico que se aplicarían para un fármaco nuevo, se garantiza la seguridad del paciente cuando aplicamos la IA para el diagnóstico [1].

Existen diferentes formas de gestionar esta regulación en el proceso de validación de los sistemas de IA. Por lo general, las dos vías más utilizadas en la aprobación de estos productos en el entorno de la FDA son la vía 510k y la vía premercantil (*premarket approval*), más ardua. En el marco europeo, por lo general más laxo que el sistema americano, no existe una agencia reguladora centralizada y la validación de los dispositivos se maneja a través de **Cuerpos Notificados**: organizaciones acreditadas para la emisión de una



nota de Conformidad Europea. Los autores coinciden en la necesidad de una mayor uniformidad así como en la conveniencia de crear una base de datos pública en Europa que recoja todos los dispositivos -incluidos los sistemas de IA- dotados de la Conformidad Europea [1].

Inconvenientes tecnológicos de la IA	Implicaciones éticas	Posibles soluciones
Cajas negras de la IA	Riesgo de validación de lo desconocido.	IA debe ser transparente. Uso exclusivo de aproximaciones algorítmicas a la IA.
Complejidad de los modelos de IA	Modelos de IA no accesibles y/ o no comprensibles para el radiólogo.	Exigencia de que la IA sea explicable e interpretable. Adecuado entrenamiento a los radiólogos para entender los principios básicos de la IA y de los modelos radiológicos de IA.
Riesgo de <i>overfitting</i>	Impacto en el diagnóstico radiológico.	Adecuado entrenamiento de la IA: estudios multicéntricos con validación clínica de los datos de imagen utilizados.
Dificultad de acceso a grandes cantidades de datos	Propiedad de los datos, uso de los datos y protección de la privacidad de los usuarios.	Consentimiento informado de los pacientes indicando si dejan sus estudios de imagen para entrenamiento del algoritmo. Hacer todo lo posible para proteger la privacidad del paciente durante el desarrollo y el uso de herramientas de IA.
Sesgo de automatización	La decisión del radiólogo puede estar sesgada por la automatización. Las tareas del radiólogo pueden ser sustituidas por IA con la consiguiente pérdida de puestos laborales.	Adecuado entrenamiento de los radiólogos en el uso apropiado de la IA en la práctica clínica. Los radiólogos que utilizan IA reemplazarán a los que no.

Tabla 2. Inconvenientes y problemas éticos de la IA con sus posibles soluciones. Adaptado de Adrian P. Brady et al [10].



Conclusiones

La Inteligencia Artificial ha venido para quedarse y crecer. Y con ella, creceremos nosotros. ¿El radiólogo será sustituido? Parece muy difícil analizar la situación y encontrar argumentos que apoyen esta presunción. Las tareas que realiza el radiólogo son muy diversas y difícilmente sustituibles en su totalidad. La situación clínica de cada caso puede llegar a ser compleja. Teniendo en cuenta que la mayoría de las tareas que realiza la IA son muy concretas, resulta más sencillo enfocar la IA como una herramienta más en poder del clínico. Es cierto que probablemente sustituya la mayoría del trabajo rutinario, monótono y predecible, pero se encontrarán maneras más provechosas de invertir el tiempo (comités multidisciplinares, liberar tiempo para los casos complejos que requieran más atención, investigación...).

Sabiendo que el panorama va a cambiar tanto, la pregunta más interesante no parece ser si el radiólogo será sustituido, sino más bien, ¿qué cambios va a tener que implementar el radiólogo para adaptarse? Para poder responder a esta pregunta, conviene entender primero la base de la IA en el ámbito de la Radiología. Es lo que se ha tratado de explicar de la manera más sencilla posible en este trabajo. Hay que entender el significado de los términos más básicos, las aplicaciones clínicas que tiene la IA en el momento actual y las más previsibles en el futuro, así como las dificultades, retos y problemas éticos que acompañan a este cambio. Llevado a cabo este rito de iniciación, se está en una posición más elevada para seguir mirando al futuro.

Referencias

1. Muehlematter UJ, Daniore P, Vokinger KN. Approval of artificial intelligence and machine learning-based medical devices in the USA and Europe (2015–20): a comparative analysis. Vol. 3, *The Lancet Digital Health*. Elsevier Ltd; 2021. p. e195–203.
2. Neri E, de Souza N, Brady A, Bayarri AA, Becker CD, Coppola F, et al. What the radiologist should know about artificial intelligence – an ESR white paper. *Insights into Imaging*. 2019 Dec 1;10(1).
3. Martín Noguero T, Paulano-Godino F, Martín-Valdivia MT, Menias CO, Luna A. Strengths, Weaknesses, Opportunities, and Threats Analysis of Artificial Intelligence and Machine Learning Applications in Radiology. *Journal of the American College of Radiology*. 2019 Sep 1;16(9):1239–47.
4. Kapoor N, Lacson R, Khorasani R. Workflow Applications of Artificial Intelligence in Radiology and an Overview of Available Tools. *Journal of the American College of Radiology*. 2020 Nov 1;17(11):1363–70.
5. Glover M, Daye D, Khalilzadeh O, Pinykh O, Rosenthal DI, Brink JA, et al. Socioeconomic and Demographic Predictors of Missed Opportunities to Provide Advanced Imaging Services. *Journal of the American College of Radiology*. 2017 Nov 1;14(11):1403–11.
6. Shi F, Wang J, Shi J, Wu Z, Wang Q, Tang Z, et al. Review of Artificial Intelligence Techniques in Imaging Data Acquisition, Segmentation, and Diagnosis for COVID-19. Vol. 14, *IEEE Reviews in Biomedical Engineering*. Institute of Electrical and Electronics Engineers Inc.; 2021. p. 4–15.
7. Zhang Z, Seeram E. The use of artificial intelligence in computed tomography image reconstruction - A literature review. Vol. 51, *Journal of Medical Imaging and Radiation Sciences*. Elsevier Inc.; 2020. p. 671–7.
8. Katzen J, Dodelzon K. A review of computer aided detection in mammography. Vol. 52, *Clinical Imaging*. Elsevier Inc.; 2018. p. 305–9.
9. Pesapane F, Codari M, Sardanelli F. Artificial intelligence in medical imaging: threat or opportunity? Radiologists again at the forefront of innovation in medicine. Vol. 2, *European Radiology Experimental*. Springer; 2018.
10. Brady AP, Neri E. Artificial intelligence in radiology-ethical considerations. *Diagnostics*. 2020 Apr 1;10(4).