

INTELIGENCIA ARTIFICIAL EN IMAGENOLÓGÍA. REVISIÓN DE CONCEPTOS, APLICACIONES Y CONSECUENCIAS.

Dr. Gustavo Febles

RESUMEN

Se trata el tema de la inteligencia artificial y sus aplicaciones en Imagenología.

Se analiza el impacto que esta tecnología tendrá en la actividad del médico imagenólogo y los pasos que el mismo deberá dar para adaptarse a los cambios.

Es una revisión bibliográfica que aporta y confiere un orden a conceptos relevantes vinculados a la inteligencia artificial en Imagenología, con el objetivo de ayudar a lograr una comprensión global e integradora del tema.

Palabras clave: *Inteligencia artificial; machine-learning; deep-learning.*

INTRODUCCIÓN

El mundo de la inteligencia artificial está en continua expansión y ocupa cada vez más espacios en nuestra vida cotidiana. Tiene actualmente una amplia gama de aplicaciones y como ejemplos podemos mencionar: los motores de búsqueda, la detección de fraude en el uso de tarjetas de crédito, el análisis del mercado de valores, el reconocimiento del habla y del lenguaje escrito, los juegos, la robótica y las aplicaciones médicas.

En el ámbito de la medicina, el diagnóstico por imágenes es un campo lleno de oportunidades para el desarrollo de la inteligencia artificial.

La Imagenología consiste esencialmente en extraer características de las imágenes, interpretar dichas características basándose en un conocimiento previamente adquirido y elaborar un diagnóstico. Ésta es una secuencia de pasos que puede ser emulada eficientemente por los sistemas informáticos.

Es sorprendente la cantidad y diversidad de publicaciones que existen actualmente referidas a la inteligencia artificial y sus aplicaciones en Imagenología. Esta multitud de fuentes bibliográficas hace difícil la comprensión del tema en forma global e integradora.

El objetivo de este trabajo es establecer un orden en los conceptos relevantes, de tal manera que sirva de base para la comprensión del tema y como guía para aquellos que deseen profundizar en el mismo.

Se realizó una revisión bibliográfica y se aportan las definiciones importantes, la descripción de las aplicaciones

de la inteligencia artificial en Imagenología, las bases para su implementación y un análisis de las consecuencias que tendrá en la actividad del médico imagenólogo.

DEFINICIONES

El médico imagenólogo debe familiarizarse con la terminología utilizada en el mundo de la inteligencia artificial. A continuación aportaremos las definiciones y conceptos relevantes vinculados a esta tecnología.

Inteligencia artificial

Inteligencia artificial es la tecnología que estudia, diseña y desarrolla sistemas informáticos computarizados que tienden a emular algunas de las funciones propias de la inteligencia humana (1), tales como la capacidad de aprender para resolver problemas.

La esencia del funcionamiento de la inteligencia artificial se basa en algoritmos. Un algoritmo es un conjunto de instrucciones o reglas bien definidas, ordenadas y finitas, que permite llevar a cabo una actividad mediante pasos sucesivos, que no generen dudas a quien deba hacer dicha actividad. Dados un estado inicial y una entrada, siguiendo los pasos sucesivos, se llega a un estado final y se obtiene una solución.

La inteligencia artificial emplea un conjunto de instrucciones informáticas diseñadas para realizar una tarea específica.

Machine learning (aprendizaje automático)

Machine learning (ML) es un campo de la inteligencia

artificial que consiste en la práctica de usar algoritmos informáticos para analizar y clasificar datos, aprender de ellos y luego ser capaces de hacer una predicción o sugerencia sobre algo (2).

El sistema ML comienza con un conjunto de entradas (inputs) y finaliza con un conjunto de salidas (outputs). Los inputs comunes en Imagenología son características de la imagen y del paciente, las cuales se etiquetan manualmente. Los outputs son un conjunto de condiciones y probabilidades asociadas (Ejemplo: la probabilidad de que un nódulo mamario, visible en una mamografía, sea un tumor mamario maligno) (3).

El sistema debe cumplir una etapa de entrenamiento durante la cual se ingresan las imágenes con las etiquetas correspondientes. Durante esa etapa los algoritmos de ML se perfeccionan a medida que se exponen a más datos, es decir que, aprenden a dar una respuesta específica mediante la evaluación de un gran número de exámenes que han sido etiquetados a mano (4).

Esta forma de entrenamiento se denomina "supervisado". La mayoría de los sistemas para diagnóstico por imágenes siguen este proceso.

Antes de estar apto para su uso en la práctica clínica, el sistema debe ser testeado y validado. Se utiliza un conjunto de ejemplos "ocultos" con el objetivo de aumentar la confianza de que el algoritmo arrojará respuestas correctas en el mundo real.

Representation learning (aprendizaje por representación)

Representation learning es un subtipo de ML en el cual no se proporcionan las características de la imagen etiquetadas a mano. En cambio, el algoritmo de la computadora aprende las características requeridas para clasificar los datos proporcionados.

El sistema encuentra por sí mismo las características importantes como parte del proceso de búsqueda. Se elimina la limitación de analizar solamente aquellas características que un ser humano considera importantes. El sistema puede decidir que características importantes de la imagen va a analizar, e incluso algunas de estas características pueden ser imperceptibles para el ojo humano. Este sistema de entrenamiento se denomina "no supervisado".

Si se proporcionan suficientes datos de capacitación, los sistemas basados en el aprendizaje por representación pueden lograr un mejor rendimiento que los sistemas ML tradicionales que incorporan características "hechas a mano". (5)

Aprendizaje profundo (deep learning)

Deep Learning (DL) es un subconjunto dentro del campo del Representation Learning (RL). Es una forma avanzada de RL que explora el uso de redes neuronales artificiales, una forma de algoritmo inspirado en la estructura y función del cerebro humano.

Esa red artificial de neuronas está compuesta por distintas capas, conexiones y una dirección en la que se propagan los datos atravesando cada capa con una tarea específica. (6)

Se toma una imagen como información de entrada de la primera capa. Allí será particionada en miles de trozos que cada neurona analizará por separado. Cada capa es experta en analizar alguna característica de la imagen y le va asignando un peso. Finalmente, las capas finales de neuronas recogen esa información y ofrecen un resultado. (7)

Esta tecnología se está desarrollando rápidamente y tiene la potencialidad de realizar la detección automática de una lesión en las imágenes, sugerir diagnósticos diferenciales y estructurar un informe preliminar (8).

Las redes neuronales convolucionales (convolutional neural networks) funcionan con entradas (inputs) tanto bidimensionales, como tridimensionales y son las que están ganando mayor interés en la imagen médica. (9,10)

APLICACIONES DE LA INTELIGENCIA ARTIFICIAL EN IMÁGENOLOGÍA

Los sistemas de inteligencia artificial tienen múltiples aplicaciones en Imagenología y la investigación es constante para tratar de incorporar más campos de acción. El objetivo de este desarrollo es atender necesidades no satisfechas o mejorar las soluciones existentes.

Se pueden definir 3 escenarios para la aplicación de la IA: el escenario de screening o tamizaje, el escenario de reemplazo y el escenario de complementación. (6)

Screening o tamizaje:

En este escenario la IA se utiliza como una herramienta de detección para clasificar los estudios de acuerdo a la probabilidad de la presencia de una enfermedad (estudio positivo o negativo). Un ejemplo puede ser el análisis de la gran cantidad de estudios de imagen que se realizan en una institución, para priorizar la lectura de aquellos en los cuales hay alguna anomalía potencialmente relevante. Los casos seleccionados deberán ser analizados e informados en forma prioritaria por un médico imagenólogo (11).

En este escenario operan los sistemas de detección asistida por computadora (CAD). Este tipo de software existen desde hace varios años en radiología y su función es marcar en la imagen áreas de potencial interés. Es el médico radiólogo el que finalmente define si la zona marcada tiene, o no, interés diagnóstico. Con el desarrollo de la inteligencia artificial es posible aumentar la precisión de los CAD. Ejemplos de su aplicación son: el screening del cáncer de mama con mamografía (12), el screening del cáncer de pulmón(13-15) y el diagnóstico temprano de la enfermedad de Alzheimer. (16-18)

Reemplazo:

Existen algunas áreas en las cuáles la IA tiene la capacidad de reemplazar a los médicos imagenólogos. Esto debería estar limitado a situaciones en las cuáles los resultados de la IA son consistentemente más precisos, rápidos, reproducibles, y más fáciles de obtener. Un ejemplo sería la estimación de la edad ósea por un software de inteligencia artificial que proporciona consistentemente mejor

rendimiento que un médico radiólogo (19).

La FDA ya aprobó el software llamado ContactCT que analiza las imágenes de tomografías computadas, solicitadas por el cuadro clínico de stroke (20). Si el sistema detecta el bloqueo de un gran vaso, automáticamente envía un mensaje al especialista neurovascular. El médico radiólogo no interviene en el proceso. La FDA reconoce que este software tiene la capacidad de notificar al especialista en un tiempo menor y con una precisión similar a la de un médico radiólogo.

En este escenario también se encuentra el cálculo de la densidad radiológica mamaria y el establecimiento de un score de riesgo (21).

Otro ejemplo en este escenario es la determinación de un score de calcificación de las arterias coronarias en tomografía (22).

También se han desarrollado observadores automatizados como un sustituto para observadores humanos para evaluar la calidad de las imágenes en diferentes áreas de la Imagenología (23-25).

Complementación:

En esta situación hay un análisis y un informe de los estudios por parte del médico imagenólogo y un aporte complementario del sistema de inteligencia artificial. El sistema puede apoyar el diagnóstico realizado, hacer un diagnóstico no concordante con el del médico (lo cual obliga a revisar las imágenes), brindar una lista de diagnósticos diferenciales, aportar información adicional, o brindar herramientas para mejorar el flujo de trabajo. Existen múltiples aplicaciones de la IA en uso o en desarrollo enmarcadas en este escenario: registro y segmentación, interpretación y clasificación automática, cálculo de la dosis de radiación, integración automática de datos, mejora en la calidad de los informes radiológicos.

Registro y segmentación de las imágenes:

La extracción de datos clínicamente relevantes de imágenes médicas requiere un registro y segmentación precisos de la imagen.

El registro de imágenes consiste en superponer e integrar varias imágenes de un mismo objeto, adquiridas en diferentes instantes, con dispositivos diferentes (diferentes técnicas de imagen), o bajo condiciones diferentes. En este proceso una de las imágenes permanece sin modificar (imagen de referencia o fija), mientras que las otras se transforman geométricamente hasta que se ajustan a la de referencia (26).

La segmentación es el reconocimiento y la delimitación de un objeto en una imagen (Ejemplo: la delimitación de los contornos y composición de una lesión en un órgano a partir de una serie de imágenes) (6).

Existen varios ejemplos de la aplicación de estos procesos en Imagenología: el estudio de tumores hepáticos; el diagnóstico de cáncer pulmonar (27); el análisis de tumores cerebrales (28), la evaluación de las lesiones de una esclerosis múltiple (29-31); la segmentación para el estudio del cartílago tibial (32); el análisis de la estructura ósea en radiografía simple. (33)

Interpretación y clasificación automática:

La interpretación de los hallazgos detectados en imágenes médicas requiere conocimiento, experiencia y juicio clínico.

Varios estudios han demostrado que el aprendizaje automático podría mejorar la interpretación de los hallazgos como una ayuda para el radiólogo, pero para que una máquina funcione como un intérprete de imágenes independiente, se requiere una gran adquisición de conocimiento derivado de grandes bases de datos.

Sin embargo, en el terreno de la informática se sigue experimentando para aumentar las capacidades de las máquinas. Está en marcha un proyecto con el supercomputador Watson Health de la firma IBM. Se sometieron las imágenes de varios estudios de radiodiagnóstico a la mirada de Watson (WatsonEyes) y se observó como la computadora descartaba los posibles diagnósticos y tomaba una decisión diagnóstica. El proceso es similar al que puede llevar a dicho diagnóstico por un humano, teniendo no sólo en cuenta las características de la imagen, sino integrando los datos clínicos del paciente (34). Sistemas inteligentes de apoyo a la decisión clínica podrían mejorar la calidad de la atención y la eficiencia de la imagen y reducir la probabilidad de eventos adversos o la ocurrencia de errores diagnósticos.

Una red neuronal se puede entrenar también como un clasificador de imágenes donde las categorías se definen de acuerdo a las características imagenológicas de las lesiones. El Colegio Americano de Radiología brinda asesoramiento para este tipo de clasificación en varias áreas de la Imagenología, por el sistema Reporting and Data Systems (RADS). (35)

Cálculo automático de la dosis de radiación:

El aprendizaje automático podría usarse para la estimación de la dosis de radiación que específicamente recibe un órgano, a partir de un conjunto de imagen CT. Un estudio reciente reveló una precisión de más del 96% en la estimación de la dosis cuando se emplea una red neuronal convolucional en conjuntos de datos CT. (36)

Otro ejemplo habitualmente usado en mamografía digital directa, es el cálculo de la dosis glandular media para cada proyección mamográfica.

Integración automática de datos:

En los registros médicos electrónicos existe un conjunto heterogéneo de datos

de varias fuentes, incluidos historiales médicos y notas de progreso, resultados de laboratorio, informes de imágenes y de patología, genómica y otros. La disponibilidad de estos datos brinda oportunidades sin precedentes para la extracción de información, pero también plantea desafíos para la integración de fuentes de datos heterogéneas. (37) Varias técnicas de aprendizaje automático podrían aplicarse para la integración y análisis de datos. (38)

La disponibilidad de una gran cantidad de información en los registros médicos electrónicos permite la creación de grupos de datos interdisciplinarios que podrían usarse

para la predicción de resultados individuales, análisis y toma de decisiones clínicas. Esto podría dar lugar a medicina personalizada (o medicina de precisión), en la que la variabilidad genética, el medio ambiente y los factores de estilo de vida, se toman en cuenta para la prevención de enfermedades, el tratamiento y pronóstico.

El denominado Radiomics es un proceso que extrae una gran cantidad de características cuantitativas de imágenes médicas (39). Puede potencialmente aplicarse a cualquier condición médica, pero actualmente es aplicado principalmente en oncología para la cuantificación del fenotipo tumoral y para el desarrollo de herramientas de apoyo a la decisión. El proceso tiene el potencial de ayudar a predecir un resultado importante, como puede ser la mortalidad específica de un cáncer.

Mejora en la calidad de los informes radiológicos:

En este terreno debemos considerar las aplicaciones del Natural Language Processing (NLP) que consiste en la conversión de texto no estructurado en una forma estructurada que permita la extracción automatizada de información (40,41).

NLP ofrece una variedad de aplicaciones en Imagenología y algunos ejemplos son: la vigilancia diagnóstica, identificando casos para estudios de investigación; la evaluación de la calidad de la práctica radiológica; la mayor eficiencia en la codificación administrativa de informes de radiología, acelerando la revisión electrónica de historias clínicas; el apoyo al diagnóstico ofreciendo diagnósticos diferenciales a partir de los hallazgos descritos; la estructuración automatizada de los informes colaborando en la creación de informes de mayor calidad que combinen los hallazgos con guías clínicas basadas en evidencia. A partir de datos extraídos del texto existen programas de recuperación automática que podrían recuperar estudios previos de otros pacientes con hallazgos de imagen similares, para contribuir con información útil para el diagnóstico.

IMPLEMENTACIÓN DE LA INTELIGENCIA ARTIFICIAL EN IMÁGENOLOGÍA

La implementación de técnicas de la inteligencia artificial en imágenes médicas presenta varios desafíos que debe superar. Los diagnósticos no siempre se confirman; las clasificaciones y los conceptos no son siempre unánimes, ni tampoco son eternos. Las estructuras del cuerpo humano presentan una gran variación en términos de sus dimensiones y texturas normales y tales variaciones podrían enmascarar algunas condiciones patológicas.

A pesar de los muchos resultados prometedores de las primeras investigaciones, hay varios problemas que deben resolverse antes de la introducción de la inteligencia artificial en la práctica de la Imagenología (9), En primer lugar está la alta dependencia en la calidad y cantidad de los datos de entrenamiento y de validación.

La elaboración de conjuntos de datos de entrenamiento y conjuntos de datos de validación es de capital importancia. Estos conjuntos de datos deben ser generalizables, teniendo en cuenta diferencias geográficas en la prevalencia de las enfermedades, diferentes tipos de equipos (diferencias entre fabricantes) y diferentes protocolos de los estudios en las instituciones de todo el mundo. Además estos conjuntos de datos deben ser actualizados a intervalos regulares y deben eliminarse todos los elementos que permitan identificar a una persona en particular (confidencialidad).

El Instituto de Ciencias de Datos del Colegio Americano de Radiología (Data Science Institute) está buscando aportes de la industria sobre los primeros casos de uso de inteligencia artificial que se publicarán en su biblioteca Touch-AI (42). El ACR DSI considerará los comentarios antes del lanzamiento programado este año 2018. Se tratará de una descripción de los pasos o las actividades que deberán realizarse para la implementación de la inteligencia artificial. Se definirá cómo los algoritmos de IA recibirán información (imágenes, datos de registros de salud electrónicos), ejecutarán el modelo de IA y proporcionarán resultados específicos, como detección y clasificación, cuantificación y priorización de la información para los usuarios finales.

También se proporcionarán parámetros específicos sobre el entrenamiento, evaluación y validación de los algoritmos de inteligencia artificial para la aprobación reglamentaria y el uso clínico. Se establecerán guías para la implementación en la práctica clínica, dentro de los flujos de trabajo existentes y guías para monitorear su efectividad.

IMPACTO DE LA INTELIGENCIA ARTIFICIAL EN LA ACTIVIDAD DEL MÉDICO IMAGENÓLOGO

La inteligencia artificial tiene cada vez más aplicaciones en Imagenología. Sin dudas este proceso va a generar cambios en la vida profesional de los médicos imagenólogos, aunque todavía no está claramente definida cuál va a ser la naturaleza de dichos cambios.

Algunos piensan que la introducción de estas tecnologías puede acabar con el papel del médico imagenólogo, pero la mayoría de los autores estima que estas técnicas van a mejorar el flujo de trabajo, van a aumentar la productividad del radiólogo y van a mejorar el cuidado y la satisfacción del paciente (43).

Se puede decir que, en el proceso evolutivo de la inteligencia artificial aplicada a la Imagenología, conviven amenazas y oportunidades para el médico imagenólogo.

Amenazas:

En la medida en que nuestras imágenes son cada vez más cuantitativas (datos digitalizados), ellas se transforman en información más fácil de analizar por las máquinas.

En el terreno de la cuantificación, la inteligencia artificial tiene un desempeño claramente superior al del humano.

Ejemplos de esto, que ya han sido mencionados, pueden ser la estimación de la edad ósea, el cálculo de la densidad radiológica mamaria, el cálculo de la dosis de radiación. También es una realidad que los avances de la inteligencia artificial están llegando a áreas que cada vez están más cercanas a terrenos de nuestra competencia humana (interpretación y diagnóstico) (44). Ya hemos mencionado como ejemplo de esta tecnología, la supercomputadora Watson Health, que está realizando avances en el área del diagnóstico por imágenes.

El buen uso de las herramientas que aporta la inteligencia artificial tiene la capacidad de fortalecer la actividad del médico imagenólogo, pero el problema está en que los avances tecnológicos son más rápidos que el desarrollo de las normas que regulan su aplicación.

En un medio donde estas normas no están bien determinadas, existe el riesgo que grupos de empresarios médicos, actuando con fines comerciales, se apoderen de las aplicaciones de la inteligencia artificial en Imagenología, prescindiendo de la actividad del médico imagenólogo. Esta situación no sería una novedad para Uruguay, donde ocurre que hay áreas de la Imagenología en las cuáles se desempeñan médicos de otras especialidades o médicos que no han completado ninguna especialidad de postgrado.

Aun considerando que se alcance el desarrollo de una normativa adecuada desde el punto de vista ético, laboral y médico-legal, que regule las aplicaciones de inteligencia artificial en Imagenología, los médicos imagenólogos deberán adaptarse a los cambios para poder conservar sus puestos de trabajo. Aun en estas condiciones de trabajo, adecuadamente reguladas, habrá un desplazamiento de algunos médicos imagenólogos, ya que aquellos que estén capacitados para usar la inteligencia artificial reemplazarán a aquellos que no lo estén.

Oportunidades:

Actualmente, no hay evidencia de que la inteligencia artificial, en condiciones de trabajo reguladas, pueda reemplazar a los médicos imagenólogos, sino que puede mejorar el rendimiento de los mismos en muchos aspectos. Sin embargo, como ya mencionamos, el avance tecnológico hace imprescindible que el médico imagenólogo siga un proceso de adaptación.

En primer lugar hay que definir hacia donde hay que dirigir los mayores esfuerzos para ganar terreno y avanzar. En el terreno de la detección, segmentación, clasificación y cuantificación, los médicos imagenólogos perderemos frente a la inteligencia artificial.

En el terreno de la inferencia aún somos superiores a las

máquinas y todavía podríamos prevalecer si trabajamos en ese sentido.

El término inferir se refiere al proceso de llegar a una conclusión basada en evidencias existentes, todo mediante un pensamiento lógico que considera todos los factores presentes de manera objetiva, para luego tomar una decisión o determinación informada (Fuente: <http://quesignificado.com/inferir/>)

En el caso de la Imagenología este proceso implica la integración de los datos aportados por las imágenes con conceptos de diferentes campos científicos y especialidades clínicas (por ejemplo, física médica, informática, epidemiología, patología, oncología) para proporcionar explicaciones plausibles para los hallazgos.

El médico imagenólogo debe profundizar su capacitación en un área específica de la Imagenología. En esa área debe dominar todas las técnicas de imagen y además debe incorporar conocimientos de otras disciplinas afines. Solamente con esta capacitación podrá interactuar en igualdad de condiciones con el médico clínico y podrá ser un factor importante en la resolución del problema del paciente.

La inteligencia artificial podría reducir el tiempo requerido para leer imágenes y proporcionar más tiempo para que el imagenólogo desempeñe un papel diagnóstico más eficaz, mediante el análisis de datos de una variedad de fuentes, en lugar de solo datos basados en imágenes.

Además el médico imagenólogo debe potenciar su rol en el control de calidad del proceso diagnóstico, así como participar en debates multidisciplinarios y actuar como consultor para la selección del método de imagen más apropiado para abordar un problema clínico determinado.

También es importante que en cada subespecialidad de la Imagenología, el médico imagenólogo incremente su capacitación y experiencia en la realización de los procedimientos intervencionistas para fines de diagnóstico o terapéuticos. Debe transformarse en el referente y consultante para la realización de estos procedimientos.

Los programas de postgrado y residencia deberían modificar sus planes de estudio para adaptarse a estos cambios. Actualmente es imprescindible que el conocimiento vinculado a las imágenes médicas vaya acompañado de bases sólidas en disciplinas afines (por ejemplo, clínica, patología, cirugía, oncología). También debe potenciarse la capacitación en disciplinas tales como: física médica, protección radiológica, gestión, informática y estadística médica.

Ante el avance de la inteligencia artificial, la persistencia del médico imagenólogo en un rol relevante para el proceso de atención sanitaria, depende de la adopción de una actitud proactiva para generar los cambios adaptativos que son imprescindibles.

CONCLUSIONES

La Imagenología es una disciplina que genera muchas oportunidades para el desarrollo de la inteligencia artificial. Es evidencia de ello la multitud de investigaciones y publicaciones que existen en esta área.

El avance tecnológico es muy rápido y el médico imagenólogo debe prepararse para anticiparse a los grandes cambios que sin duda van a ocurrir.

Ya terminó la época del médico imagenólogo generalista, limitado a describir imágenes y aislado del resto del proceso clínico.

El médico imagenólogo actual debe ser un profesional subespecializado en un área de la Imagenología, altamente capacitado en el análisis de las imágenes y en disciplinas afines a su subespecialidad. Además debe dominar los aspectos técnicos y la lógica de funcionamiento de los sistemas de inteligencia artificial. Solamente en estas condiciones podrá apoderarse de las nuevas tecnologías y no ser sustituido por ellas.

BIBLIOGRFÍA

Merriam-Webster definition of artificial intelligence. Disponible en: <https://www.merriam-webster.com/dictionary/artificial-intelligence>. Consultado: junio, 2018.

Diccionario de lengua española. Real Academia Española. www.dle.rae.es. Consultado: junio 2018.

Kohli M, Prevedello L, Filice R, Geis JR: Implementing Machine Learning in Radiology Practice and Research. *AJR*. 2017; 208:754-760.

Jordan M, Mitchell TM: Machine learning: trends, perspectives and prospects. *Science* 2015; 349: 255-260.

Erickson B, Korfiatis P, Akkus Z, Kline T: Machine learning for medical imaging. *Radiographics* 2017; 37:505-515.

Tang A, Tam R, Cadrin-Chenevert A, Guest W, Chong J, Barfett J et al. Canadian Association of Radiologists White Paper on Artificial Intelligence in Radiology. *Canadian Association of Radiologists Journal*. 2018; 69:120-135.

Chartrand G, Cheng PH, Vorontsov E, Drodzal M, Turcotte S, Pal CH et al.: Deep learning: a primer for radiologists. *Radiographics* 2017; 37(7): 2113-2131.

LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature* 2015;521:436-444.

June-Goo L, Sanghoon J, Young-Won Ch, Hyunna L, Guk Bae K, Joon Beom S, Namkug K. Deep Learning in Medical Imaging: General Overview. *Korean J Radiol* 2017;18(4):570-584.

Shen D, Wu G, Suk HI. Deep learning in medical image analysis. *Annu Rev Biomed Eng* 2017; 19(1): 221-248.

vRad and MetaMind collaborate on deep learning powered workflows to help radiologists accelerate identification of life-threatening abnormalities. Disponible en: <http://>

www.prweb.com/releases/2015/06/prweb12790975.htm. Published June 16, 2015. Consultado: julio, 2018.

Becker AS, Marcon M, Ghafoor S, Wurnig MC, Frauenfelder T, Boss A. Deep learning in mammography: diagnostic accuracy of a multipurpose image analysis software in the detection of breast cancer. *Invest. Radiol*. 2017;52:434-440.

Hua KL, Hsu CH, Hidayati SC, Cheng WH, Chen YJ. Computer-aided classification of lung nodules on computed tomography images via deep learning technique. *Oncotargets Ther* 2015;8:2015-2022.

Kumar D, Wong A, Clausi DA, eds. Lung Nodule Classification Using Deep Features in CT Images. *Proceedings of 2015 12th Conference on Computer and Robot Vision*; 2015 June 3-5; Halifax, Canada. IEEE, 2015:133-138.

Liu Y, Balagurunathan Y, Atwater T, et al. Radiological image traits predictive of cancer status in pulmonary nodules. *Clin. Cancer Res*. 2017; 23(6): 1442-1449.

Suk HI, Lee SW, Shen D; Alzheimer's Disease Neuroimaging Initiative. Hierarchical feature representation and multimodal fusion with deep learning for AD/MCI diagnosis. *Neuroimage* 2014;101:569-582.

Suk HI, Shen D. Deep learning-based feature representation for AD/MCI classification. *Med Image Comput Assist Interv* 2013;16(Pt 2):583-590.

Liu S, Lis S, Cai W, Pujol S, Kikinis R, Feng D, eds. Early diagnosis of Alzheimer's disease with deep learning. *Proceedings of the IEEE 11th International Symposium on Biomedical Imaging*; 2014 April 29-May 2; Beijing, China. IEEE, 2014:1015-1018.

Lee H, Tajmir S, Lee J, et al. Fully automated deep learning system for bone age assessment. *J.Digit.Imaging*. 2017;

30(4): 427-441.

U.S. Food and Drug Administration. FDA permits marketing of clinical decision support software for alerting providers of a potential stroke in patients. <https://www.fda.gov/NewsEvents/Newsroom/PressAnnouncements/ucm596575.htm>

Kallenberg M, Petersen K, Nielsen M, et al. Unsupervised deep learning applied to breast density segmentation and mammographic risk scoring. *EEE Trans Med Imaging* 2016;35(5):1322-1331.

Schuhbaeck A, Otaki Y, Aschenbach S, et al. Coronary calcium scoring from contrast coronary CT angiography using semiautomated standardized method. *J. Cardiovasc. Comput. Tomogr.* 2015; 9(5): 446-453.

Kalayeh MM, Marin T, Brankov JG. Generalization evaluation of machine learning numerical observers for image quality assessment. *IEEE Trans Nucl Sci* 2013;60(3):1609-1618.

Eck BL, Fahmi R, Brown KM, et al. Computational and human observer image quality evaluation of low dose, knowledge-based CT iterative reconstruction. *Med Phys* 2015;42(10):6098-6111.

Esses SJ, Lu X, Zhao T, et al. Automated image quality evaluation of T2 -weighted liver MRI utilizing deep learning architecture. *J Magn Reson Imaging* 2017 Jun 3. [Epub ahead of print]

Arévalo V. Registro de imágenes mediante transformaciones lineales por trozos. Tesis Doctoral. Ingeniería de sistemas y automática. Universidad de Málaga. Disponible en: <http://mapir.isa.uma.es/varevalo/drafts/arevalo2008PhD.pdf> . Consultado: julio 2018.

Middleton I, Damper RI. Segmentation of magnetic resonance images using a combination of neural networks and active contour models. *Med Eng Phys* 2004;26:71-86.

Pereira S, Pinto A, Alves V, Silva CA. Brain tumor segmentation using convolutional neural networks in MRI images. *IEEE Trans Med Imaging* 2016;35:1240-1251.

Moeskops P, Viergever MA, Mendrik AM, de Vries LS, Benders MJ, Isgum I. Automatic segmentation of MR brain images with a convolutional neural network. *IEEE Trans Med Imaging* 2016;35:1252-1261

Brosch T, Yoo Y, Tang LYW, Li DKB, Traboulsee A, Tam R. Deep convolutional encoder networks for multiple sclerosis lesion segmentation. In: Navab N, Hornegger J, Wells WM, Frangi AF, eds. *Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015*. New York: Springer, 2015:3-11

Brosch T, Tang LY, Yoo Y, Li DK, Traboulsee A, Tam R.

Deep 3D convolutional encoder networks with shortcuts for multiscale feature integration applied to multiple sclerosis lesion segmentation. *IEEE Trans Med Imaging* 2016;35:1229- 1239

Prasoon A, Petersen K, Igel C, Lauze F, Dam E, Nielsen M. Deep feature learning for knee cartilage segmentation using a triplanar convolutional neural network. *Med Image Comput Comput Assist Interv* 2013;16(Pt 2):246-253.

Glavan CC, Holban S. Segmentation of bone structure in X-ray images using convolutional neural network. *Adv Electr Comput Eng* 2013;13:87-94.

Watson HealthImaging. Disponible en: <https://www.ibm.com/watson/health/imaging/> Consultado: Julio 2018.

American College of Radiology. Reporting and data systems. Disponible en: <https://www.acr.org/Clinical-Resources/Reporting-and-Data-Systems>. Consultado: julio, 2018.

Cho J, Lee E, Lee H, et al. Machine learning powered automatic organ classification for patient specific organ dose estimation. SIIM 2017 Scientific Session. Massachusetts General Hospital, Harvard Medical School, 2017.

Greene CS, Tan J, Ung M, Moore JH, Cheng C. Big data bioinformatics. *J Cell Physiol* 2014;229(12):1896-1900.

Li Y, Wu FX, Ngom A. A review on machine learning principles for multiview biological data integration. *Brief Bioinform* 2016 Dec 22 [Epub ahead of print].

Gillies RJ, Kinahan PE, Hricak H. Radiomics: images are more than pictures, they are data. *Radiology* 2016;278:563-577.

Pons E, Braun LM, Hunink MG, Kors JA. Natural language processing in radiology: a systematic review. *Radiology* 2016;279:329-343.

Cai T, Giannopoulos A, Yu S, Kelil T, Ripley B, Kumamaru K, Rybicki F, Mitsouras D. Natural Language Processing Technologies in Radiology Research and Clinical Application. *RadioGraphics* 2016; 36:176-191.

ACR DSI Releases Initial Use Cases for Industry Feedback. Disponible en: <https://www.acr.org/Media-Center/ACR-News-Releases/2018/ACR-DSI-Releases-Initial-Use-Cases-for-Industry-Feedback> . Consultado: julio de 2018.

Choy G, Khalilzadeh O, Michalki M, Do S, Samir A, Pianyk O et al. Current applications and future impact of machine learning in Radiology. *Radiology* 2018;00: 1-11. Gálvez Moya M. Inteligencia Artificial en Radiología: ¿Seremos reemplazados por las máquinas? *Rev. chil. radiol.* 2017;23 (3). versión On-line ISSN 0717-9308.