

# INTELIGENCIA ARTIFICIAL APLICADA A LA IMAGEN MÉDICA. REVISIÓN DE TEMA.

Dres. Federico Aguirre\*, Leandro Carballo\*\*, Ximena González\*\*\*, Verónica Gigirey\*\*\*\*.

## RESUMEN

La inteligencia artificial es una disciplina que comprende un espectro amplio de funcionalidades, entre las que se destaca el análisis de las imágenes digitales. Particularmente dicha área, ha tenido un desarrollo exponencial en la última década fomentado por los avances en el deep learning. Innovaciones que han repercutido directamente en la imagenología, donde uno de los sustratos principales representa el análisis de imágenes con fin diagnóstico.

Los objetivos principales de la inteligencia artificial abarcan desde el auxilio al médico radiólogo, la optimización de la imagen, reconocimiento de estructuras, segmentación de lesiones, hasta la transcripción del informe.

Todas ellas comparten amplio potencial de impacto en la especialidad y por ende en la medicina, donde el rol de la radiología es cada día más preponderante.

En esta revisión, analizaremos publicaciones recientes, artículos de trabajos multidisciplinarios que se han desarrollado a nivel mundial; así como aplicaciones probadas en radiología, basadas en inteligencia artificial.

### Palabras clave:

**Inteligencia artificial- deep learning- imagenología- segmentación automática de lesiones- radiólogo**

## ABSTRACT

Artificial intelligence encompasses a large spectrum of functionalities, among which the digital image analysis stands out. Particularly this area, has witnessed an exponential development during the last decade, fueled by advances in deep learning. Innovations that have had a direct impact on radiology, where one of the main substrates represents the analysis of images for diagnostic purposes.

The main objectives of artificial intelligence in radiology, range from: assisting the radiologist, image optimization, structure recognition, segmentation, to the report's transcription. All of them share a wide potential in the specialty and therefore in medicine, where the role of radiology is becoming increasingly prevalent.

In this review, we will analyze recent publications, articles of multidisciplinary works that have been developed worldwide; as well as proven applications in radiology, based on artificial intelligence.

### Key words:

**Artificial intelligence- deep learning- radiology- automatic lesion segmentation- radiologist**

## INTRODUCCIÓN

La inteligencia artificial (IA) posee un sitio preponderante en la imagenología, puesto que su sustrato principal es el análisis de imágenes digitales. Esta disciplina se sigue desarrollando en forma vertiginosa y viene traspasando la frontera del campo experimental al uso clínico diario. Esto en parte a que la asequibilidad de hardware cada vez más poderosos ha permitido transformar en realidad múltiples proyectos, que teóricamente, bajo los lineamientos convencionales informáticos hubiesen sido muy difíciles de lograr. [1]

La IA se puede definir como el campo de estudio de los dispositivos inteligentes, que son aquellos agentes definidos como los que perciben su ambiente y toman acciones para maximizar su chance de cumplir objetivos. El término "inteligencia artificial" fue acuñado por John McCarthy en 1956 haciendo alusión a "la ciencia e ingenio de hacer máquinas inteligentes". Coloquialmente aplicaría cuando un dispositivo mimetiza las funciones cognitivas que los humanos entienden

inherentes a las mentes humanas, como el aprendizaje y la resolución de problemas. Lo que se comprende como inteligencia artificial convencionalmente, en su todo, engloba lo que refiera al desarrollo y diseño de sistemas computarizados que intenten realizar una tarea propia entendida culturalmente como propia de los seres humanos (ejemplo: la resolución de problemas). Representa el análisis formal y la teoría detrás del comportamiento humano ante distintos problemas. [2] Se basa en el análisis formal y estadístico del comportamiento humano.

Es controversial el límite del campo de estudio de la inteligencia artificial, en lo que concierne a qué se define como inteligencia artificial (IA). A medida que el campo de la informática ha avanzado; tareas antiguamente consideradas como "requerientes de inteligencia" se han ido removiendo de la definición conforme se han asimilado mejor sus mecanismos y

\*Médico  
Imagenólogo,  
COMECA.

\*\*Médico  
Imagenólogo,  
Ingeniero Biomédico,  
FLENI.

\*\*\*Prof. Adjto. Depto.  
Imagenología, HC.

\*\*\*\*Prof. Agdo. Depto.  
Imagenología, HC.

sus problemas han sido formalizados. Su utilidad en la imagenología se puso en boga debido al desarrollo de la deep learning (aprendizaje profundo), rama de la IA que se basa en el desarrollo de redes neurales artificiales a las que se les “enseña” al brindar data y cuya eficacia aumenta conforme aumenta su aprendizaje. [3] Con el mejor desarrollo de los hardware, la mayor capacidad de las unidades de procesamiento; muchos modelos basados en deep learning comenzaron a demostrarse más eficaces en lo concerniente al reconocimiento de imágenes, que los basados en inteligencia artificial “convencional”- no supervisada. El aprendizaje se realiza basándose en datos empíricos y se centra en el estudio de mecanismos adaptativos que permitan comportamiento inteligente de sistemas cambiantes y complejos.

Los problemas o metas tradicionales que abarcan el campo de la inteligencia artificial (IA), incluyen: razonamiento, planificación, aprendizaje, procesamiento natural del lenguaje, percepción y habilidad para manipular objetos. Por algún motivo, de todas dichas funciones de la IA; el reconocimiento de estructuras en imágenes digitales no sólo ha de ser una prometedora herramienta; sino que con el entrenamiento adecuado es considerablemente mejor que el reconocimiento humano. Esto implica un punto sensible en la imagenología; donde la inteligencia artificial traerá cambios sustanciales en el rendimiento y las formas de trabajar del médico radiólogo. Si bien nuestra especialidad hoy día, es el arquetipo de que tan lejos puede llegar la IA en la medicina, no es la primera ni será la última de las alteradas.

Aunque es muy difícil especular a largo plazo en terreno de la informática, sí lo podemos hacer en corto plazo; y ya en ese panorama se prevé a la imagenología francamente modificada por el uso de modelos y softwares de IA aplicados a sus técnicas. Es por eso que en recientes

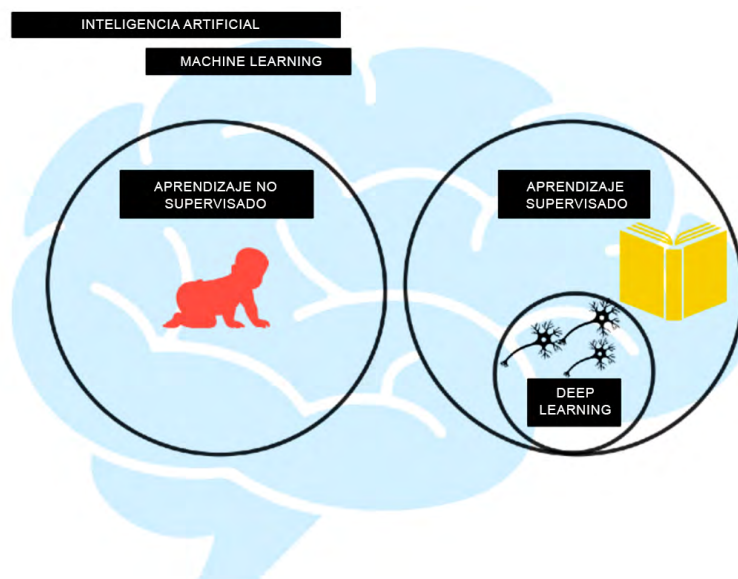
revisiones del American Journal of Radiology (AJR) se ha postulado que a 10 años los radiólogos no serán sustituidos por la inteligencia artificial, pero es muy probable que los radiólogos que manejen inteligencia artificial comiencen a sustituir a los que no la manejen. [4]

## CLASIFICACIÓN

A groso modo, el machine learning posee dos grandes subdivisiones; el aprendizaje no supervisado y el supervisado. Nos centraremos en este último, de mayor interés en nuestra especialidad:

El aprendizaje supervisado representa los postulados convencionales de la IA sumado al desarrollo interactivo; es decir, aprendizaje basado en modificaciones interactivas en los sistemas de conexiones. El deep learning es un método basado en supervisión que utiliza una arquitectura específica que remeda una red neural. El poder de esta técnica se basa en su escala y habilidad para automáticamente extraer características relevantes frente a un problema. En el pasado reciente, la construcción de un sistema de inteligencia artificial convencional llevaba mucho tiempo de inversión en la creación, producción y corrección de algoritmos, y esto es lo que últimamente ha cambiado, haciéndose cada vez más realizable.

El deep learning pone énfasis en la data que es brindada y etiquetada al sistema. Permite que éste la digiera en redes que arquitectónicamente se disponen emulando las capas del córtex de los mamíferos, haciendo sus conexiones las veces de interneuronas que enlazan las mismas. Por ejemplo, en los sistemas de reconocimiento facial generados, muchas de las características que priorizan los sistemas son similares a las del córtex visual de los mamíferos. La red, sustrato del deep learning, se compone de distintas capas, con interconexiones y una dirección en la que los datos se propagan por cada capa con una tarea específica. [5]



**Figura 1**  
**Mapa de la inteligencia artificial-machine learning.**  
Comprende los subgrupos de aprendizaje no supervisado y supervisado. Dentro del aprendizaje supervisado está demarcado el grupo de deep learning, en el que nos adentraremos puesto que es el que ha demostrado tener mayor impacto en radiología.

## DISECCIÓN DEL DEEP LEARNING LAS REDES CONVOLUCIONALES

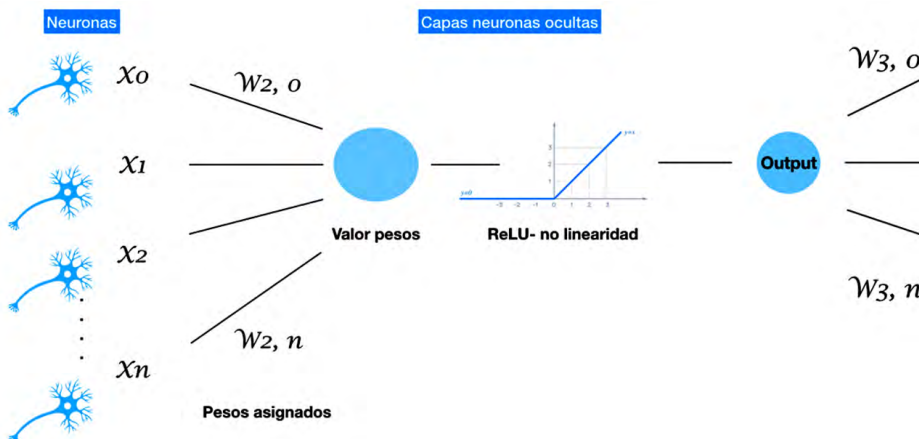
En el deep learning se han suplantado los modelos convencionales “a mano” por las redes convolucionales. Las redes convolucionales se usan para procesar imágenes. Hoy en día existen grandes avances en sus funciones, para detección de objetos y clasificación de imágenes en general, ya que pueden aprender relaciones entrada-salida; siendo la entrada una imagen y la salida una etiqueta. De ahí la preponderancia que su desarrollo puede tener en el campo de la radiología.

Se toma una imagen digital de un medio diagnóstico, supongamos, formato DICOM. Dicha imagen será particionada en miles de trozos que cada neurona del sistema analizará por separado. El sistema basado en aprendizaje profundo, comprende la actividad de diversas capas, cada una con sus funciones que irán priorizando y asignándole pesos a cada característica de la imagen obtenida. Esa información se resume, se procesa y se brinda un resultado.

Profundizaremos los lineamientos generales que componen un sistema de deep learning, realizando una analogía con las funciones cognitivas del humano en el reconocimiento de imágenes. A grandes rasgos debemos saber que cualquier sistema basado en deep learning comprende unos 5 niveles. El nivel primero de input o aferencia, la capa de convolución, activación, el pooling y la interconexión. [6] Reseñaremos cada nivel, cual disección, haciendo alusión al paralelismo con la estructura o función biológica que representa.

**Figura 2**

Podemos apreciar el primer nivel de neuronas que reciben la aferencia, las cuales envían una señal (sinapsis) a otra capa de neuronas que pondera la información según las características deseadas. Una red de interneuronas “ocultas” basadas en modelos no-lineales, determinan una nueva respuesta en función de los pesos recibidos que en última instancia dará con un output o resultado.



La imagen- la aferencia: La imagen radiológica que quiero analizar no es más que un conjunto de vóxeles o píxeles con distintas intensidades que se representan en la escala de unidades Hounsfield. Este material representaría el input, es decir la aferencia. Cada vóxel llegará a una neurona, que reproduciendo nuestro modelo humano haría las veces de una célula del córtex visual. Cada neurona del modelo tiene un valor numérico asignado y cada unión entre las mismas representa un peso. Los pesos, parodian las conexiones de las interneuronas, puesto que conectan neuronas en distintas capas y representan la fuerza de la conectividad. Cada neurona tiene varias entradas y múltiples salidas. Como veremos más adelante, la neurona está determinada por pesos y no linealidad; cada entrada se multiplica en función de un peso sináptico.

Las “neuronas” y su rol- las redes feed-forward: Las redes feed-forward, son la unidad básica funcional de los sistemas deep, capaces de aprender relaciones entrada-salida a partir de infinitos ejemplos. Se forman de muchas neuronas simples interconectadas entre sí. Es decir, en este campo de redes enlazadas, el objetivo de las redes será activarse para determinar una respuesta o output, que será posible a través de funciones no lineales. Es decir, las respuesta se basarán en funciones que no implican necesariamente sumas simples, sino más bien modelos de multiplicaciones matriciales.

Las redes arquitecturales para una aplicación específica no son siempre tan obvias. Existen capas de “redes ocultas” que tienen neuronas que tienden a superar en número a las neuronas que procesan el input o output. Estas redes ocultas son las encargadas de procesar la información, haciendo sopesar las distintas probabilidades de a qué puede corresponder una imagen. Poniendo un ejemplo, si uno quisiese procesar una imagen de una tomografía de cráneo para que un modelo determine si hay hemorragia o no; para el output o resultado final, necesitaremos dos capas de neuronas que me determinen: “hemorragia sí” o “hemorragia no”. Sin embargo, para llegar a ese resultado


final, se debe pasar por un número de redes mayores que van determinando las características enseñadas para interpretar la existencia de hemorragia.

La arquitectura de interconexiones neurales- redes convolucionales: El traspaso de la industria de la radiología, de pensar en términos de redes simples a redes convolucionales fue muy importante; \*9+685ya que, en los modelos de redes simples, los pesos se hacen demasiado fuertes para analizar una imagen estándar. Por ejemplo, sólo con imágenes de matrices típicas de 256 x 256, que equivaldrían a 65,536 vóxeles; en una pasada de 1 corte, más de 4 billones de pesos se requerirían para implementar una sola capa enteramente conectada. Las redes convolucionales calzan justo a la imagenología, porque en lugar de estas conexiones completas se aplican pequeños kernels o núcleos que ayudan a disminuir los pesos requeridos, por ende, la complejidad del sistema. Los kernels son pequeñas unidades, resúmenes que constituyen una parte fundamental del sistema operativo al aplicarse a cada imagen ya que determinan la posición de la imagen para determinar el valor de la siguiente capa. En otros términos, emulan la abstracción, tratando de resumir, esconder la complejidad de la imagen; proporcionando una interfaz limpia y uniforme, facilitándose el uso del programa. Este proceso mimetiza la fórmula matemática de la convolución, de ahí su nombre.

Las imágenes de recuerdos que guardamos en nuestra memoria y su verdadero vínculo con las imágenes obtenidas en vida real, han sido campo de estudios por investigadores que postularon los principios denominados del "modelo cuadrático convolucionado". [6] Sería imposible fijar en la memoria cada milisegundo de percepción de nuestras vidas con cada "píxel" o detalle de nuestra imagen visualizada. La convolución, en este caso, es una operación que tendría correlato con lo que naturalmente realizaríamos los humanos y nos permitiría reservar recuerdos de imágenes, mediante un promedio de píxeles con pesos asociados a una vecindad establecida. Es decir, en término fotográficos, aplicaríamos una máscara a nuestra percepción o aferencia visual que llega a nuestro córtex; resumiéndola en un formato compatible para guardarla a corto o largo plazo.

La educación del sistema- plasticidad neuronal: Cómo mencionamos la veta esencial en los modelos deep learning se corresponde al entrenamiento. Tan es así, que, si diseccáramos el cerebro de un sistema de procesamiento de imágenes, encontraríamos que el 50%-60% de las neuronas están abocadas al entrenamiento, con un restante 30-40% y 10% aproximadamente, que se utilizan para validación y testeo respectivamente.

El sistema se debe entrenar y probar con un conjunto de datos; dónde cada uno representa una entrada y una

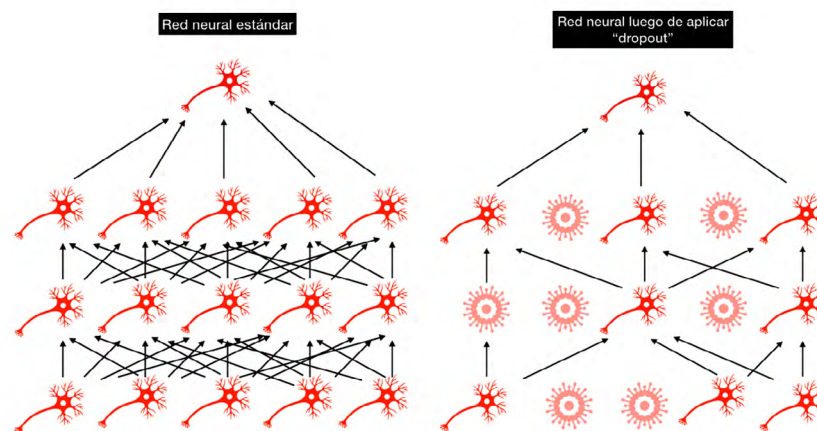


**Figura 3**  
**Representación esquemática de la operación matemática convolución, la base operacional detrás de las distintas aplicaciones de reconstrucción que el radiólogo utiliza a diario.**

En este ejemplo demostrativo se agrupan píxeles o vóxeles de una imagen, con distintas densidades que en este caso se promedian. Las convoluciones, no necesariamente implican medias como en éste figura; también son la base detrás de las reconstrucciones de máxima intensidad (MIP) o proyecciones de mínima intensidad (mini IP). En dichos casos, se agrupan un conjunto de vóxeles de la imagen cruda multiplanar; obteniéndose como resultado una imagen con los vóxeles de densidad máxima de una región o los vóxeles de densidad mínima de una región, respectivamente.

salida. Los datos forman parte de tres grupos:  
 El conjunto de datos de entrenamiento: permiten obtener los pesos de una red dada, calibrar los parámetros.  
 Los datos de validación: permiten comparar el desempeño de las distintas arquitecturas de red; lo que se conoce como el ajuste de hiperparámetros.  
 El conjunto de datos de prueba: permite estimar el desempeño de la red en datos futuros, el mejor modelo es probado aquí.  
 El sistema es entrenado y la eficacia del método va en aumento. A mayor cantidad de casos, de imágenes, mayor la experiencia del modelo. [7]  
 Un imagenólogo experto, vastamente entrenado, es probablemente más capaz de diagnosticar con precisión los signos de isquemia precoz en una tomografía de cráneo frente a un imagenólogo residente en su primer año de curso. Esto se debe a que para una misma tarea, el imagenólogo experto ha logrado “tejer” redes que funcionan con mayor eficacia y velocidad, por concepto de repetición espaciada de sinapsis. Estos cambios de neuroplasticidad, que hacen la educación y experiencia, afinan la funcionalidad de determinadas redes, así como también el número de neuronas potencialmente involucradas en dicha tarea. Permiten que uno ejecute una función con menor error.  
 Data augmentation- entrenamiento de las redes: si un modelo de deep learning se entrena en pocos ejemplos; su capacidad de predicción será mala. Antes de comenzar el entrenamiento, es necesario elegir los pesos iniciales. Es decir, el valor de cada neurona; que estará dado en función del número de entradas. Una vez asignados los pesos de cada neurona se comienza a planificar la educación del modelo, fase conocida como entrenamiento. En primer lugar, debo contar con un conjunto de “datos de entrenamiento”, éstos serán de suma importancia, pues moldearán los parámetros

de las redes. Cuántos más casos cargue como entrenamiento, mayor la eficacia del modelo. Los casos se usan para entrenar modelos. En un principio, las predicciones serán pobres. conforme aumenta el número de casos, aumento la eficacia del modelo.  
 Aparte del pool de casos de entrenamiento, existen ciertos métodos que ayudan a mejorar la eficacia independientemente del n recolectado. Es el proceso conocido como data augmentation en el cual, provocando simples variaciones que emulen errores artificiales, puedo entrenar al sistema con un mismo caso en distintas oportunidades. Una de las formas principales consiste en hacer rotar en distintos ángulos a la misma imagen, o cambiarla de posición dentro de un mismo campo; y eso determina que el sistema aprenda a reconocer el objeto de estudio independientemente de su posición por ejemplo. [7] Esto es de crucial importancia en el reconocimiento visual de tomografías o radiografías. En estudios experimentales del campo de la radiología pediátrica, respecto al diagnóstico de edad ósea; radiólogos hallaron que la alineación de una misma imagen en distintos ángulos determinaba cambios significativos en la predicción, si el sistema no había sido correctamente enseñado respecto a eso. Lo mismo podría aplicar, si hacemos que la imagen diagnóstica se encuentre en distintas posiciones del FOV (field of view).  
 Podemos definir entonces al data augmentation como el método que mejora la performance del pool de data; enseñándole además a prevenir fallos independientemente de la dirección respecto a un plano x-y, o una imagen ligeramente estrechada o ensanchada. Pero, por contrapartida, debemos tener en cuenta que estos métodos requieren de un equilibrio. Si abuso de “ense-



**Figura 4**  
 Representación esquemática, de una red neural estándar a izquierda con todas las posibles combinaciones entre las capas de neuronas e interneuronas.  
 A derecha, luego del “dropout” autogenerado por el entrenamiento del sistema, proceso que remeda la plasticidad neural. Como podemos apreciar, se simplifica la comunicación entre redes eliminándose vías de nula o escasa utilización durante el aprendizaje.

ñar” excesivamente un mismo caso al modelo, en todas las potenciales variantes que se me ocurran en cuanto a cambios en dirección, posición, etc; corro el riesgo que el modelo fije disfuncionalmente dicho caso, siendo génesis de errores de concepto. Este eventual error del sistema de deep learning es conocido como overfitting, y refiere a que el modelo toma ciertas variaciones aleatorias del caso como propias, determinando un ruido que impacta en forma negativa para el modelo cuando tome nueva data. En contraposición, el underfitting refiere a la escasez de entrenamiento con la data recolectada el modelo. La problemática de ambos problemas de entrenamiento, se da en que a ciencia cierta es difícil establecer cuando un modelo está sufriendo problemas de over o de underfitting; si bien, éstos últimos pareciesen ser los más fácilmente solucionables.

La regularización del modelo deep learning- el entrenamiento: Los postulados de la regularización consisten en minimizar una función de pérdida. El aprendizaje no sólo se hace de la reiteración de patrones de activación que posibilita una reestructuración de ciertas conexiones “sinápticas” sino que también de la debilitación de las que no se usan o se utilizan menos. Cierra entonces por completo el modelo iterativo remedando también el olvido o debilitamiento de las sinapsis de capacidades raramente usadas. Se trata de agregar términos extra a la función de pérdida. Permite mejorar la capacidad de generalización. Un porcentaje de las neuronas se desconectan en cada iteración del entrenamiento. Es así como se mejora la generalización de la red.

Lo interesante del asunto radica en que al ir pasando el conjunto de datos de entrenamiento varias veces por el modelo (looping), voy también aumentando la eficacia del mismo ya que reafirma sus aciertos y fija sus errores. Esto parte de la base que yo conozco de antemano el output o gold standard de los casos que pretendo el sistema me resuelva. Mediante las iteraciones se reforzarán los aciertos y se penalizarán los errores. Esto podremos cuantificarlo literalmente en un coeficiente denominado “cost function”, un indicador que desnuda que tan cerca el modelo está de la realidad de base, es decir el índice de correlacionamiento entre x con y. Este valor de cost function intentaré llevarlo a lo más bajo posible, mediante las sucesivas iteraciones. Y así será como monitorizaré en un principio la eficacia de mi modelo durante el entrenamiento, partiendo de una base o status quo con alto error, que mejoraré luego de varias reiteraciones destinadas a disminuir el mismatch o porcentaje de error.

Una vez que se ha optimizado el modelo, hay ciertos hiperparámetros que debo ajustar. El ajuste de estos parámetros es la segunda parte del entrenamiento, y es lo que se denomina la fase de validación. Es menester proponerse un valor adecuado de cost function como meta, el cual cómo decíamos debe ser bajo si pretendo un modelo de predicción. Para el terreno de la radiología, usualmente se utiliza como error la raíz de la media cuadrática entre lo predicho, las imágenes de referencia y los índices de similitud. [8]

## APLICACIONES DE IA EN RADIOLOGÍA

El espectro de aplicaciones es sumamente alto, y es obvio que a mayor complejidad de la tarea, más lejos se está de obtener resultados avalados por la evidencia compatibles con una labor asistencial a escala global. De menor a mayor complejidad, podemos enumerar las cuatro grandes áreas objetivos de la inteligencia artificial en la imagenología:

- 1) **Funciones de asistencia del trabajo del radiólogo.**
- 2) **Optimización de la técnica radiológica.**
- 3) **Segmentación y detección de lesiones.**
- 4) **Diagnóstico basado en imágenes.**

Estas cuatro áreas objetivo de IA en el trabajo del radiólogo están formadas de realidad y proyecciones que no han visto luz fuera del campo experimental. La importancia del crecimiento en estas áreas no hay que comprenderla exclusivamente desde la lógica de contraparte o amenaza en el mercado laboral del médico radiólogo, sino como una alternativa. Es complemento al trabajo rutinario del imagenólogo; en cuanto a los aportes de conocimiento que nutrirán la especialidad y como fin último, irán en pos de una evolución en calidad diagnóstica. Es decir, una más correcta asistencia del paciente mediante diagnósticos más certeros.

Cómo apreciamos, las áreas son diversas, desde la indicación del estudio por los clínicos, la mejora en la calidad de las imágenes, la reconstrucción de volúmenes, la detección de lesiones sospechosas, el análisis diagnóstico, llegando hasta la meta máxima que sería la transcripción de un informe en forma automática a partir de la obtención del estudio. Y existen trabajos que aplican tanto para tomografía computada (TC), resonancia magnética (RM) y tomografía por emisión de positrones- PET.

### 1) **Funciones de asistencia del trabajo del radiólogo.**

Las potenciales aplicaciones en los campos de la radiología comienzan desde la indicación del estudio. Luego que un estudio se solicita, deben aplicarse ciertos protocolos y una planificación específica, en cuanto a decidir si el estudio debe o no llevar contraste, y en qué secuencias o fases adquirir acorde al dato clínico. Cuestiones tales como la búsqueda de creatininemia reciente, datos patronímicos, antecedentes relevantes, atopías, intervenciones previas y cuadro actual; comprenden la mínima y mandatoria anamnesis del estudio radiológico. Dichas indagaciones si bien pueden llevar cuestión de minutos para cada paciente a estudiar, en el global; determinan pérdidas de tiempo consistentes. Éste tema no ha escapado de la vista para los sistemas de salud que funcionan a escala industrial, y son basados en seguros altamente sensibles a los gastos dependientes en tiempos del profesional imagenólogo. El objetivo de estas aplicaciones podemos englobarlos en la construcción de un puente electrónico a disposición del médico imagenólogo y técnico, que permita resumir una historia clínica electrónica; destacando los datos relevantes y sugiriendo una planificación específica de estudio para

dar información de interés tanto al clínico, al técnico y al médico radiólogo.

La ventaja en esta primer área de asistencia al trabajo del imagenólogo podemos encontrarla en que ya existen un montón de herramientas para la compresión de texto desarrolladas originariamente para otros fines, que permiten clasificar y priorizar información relevante, de entre muchos datos; con una rapidez inusitada y un margen de error menor al humano. En la actividad diaria sabemos que no es infrecuente la omisión de detalles de interés en las historias personales de los pacientes, sobre todo con antecedentes clínicos relevantes y tendencia al multi-estudio. Estos desarrollos podrían dar una gran ventaja a las grandes organizaciones mutuales, no sólo desde el punto de vista logístico reduciendo tiempos de adquisición entre pacientes, sino también previniendo errores aliterativos. Mejorando la interpretación de cada historia, se buscarían solicitudes más adecuadas y un outcome asistencial de más efectos positivos para el usuario.

## 2) Optimización de la técnica radiológica.

Las bases de los métodos de deep learning pueden utilizarse en la mejora de la performance de los algoritmos de reconstrucción y la calidad de imagen. Los marcos de trabajo del deep learning son capaces de “entender” los principios de la reconstrucción en tomografía y resonancia magnética.

Todos los conjuntos de datos virtuales crudos de cada técnica radiológica, son pasibles de procesamiento por modelos de deep learning que eventualmente mejoren la calidad de la imagen. Del año 2015 a esta parte, ha tomado relevancia la cantidad de estudios multidisciplinarios que buscan encontrar relaciones entre distintas secuencias de resonancia magnética. Modelos que basados en IA, con datos de una secuencia a adquirida ayudan a “predecir” información para una secuencia b por adquirir. La importancia de lograr esto radicaría en maximizar los tiempos de estudio de un paciente en resonador, en pleno apogeo de secuencias que día a día surgen para distintas indicaciones clínicas.

Un ejemplo muy representativo lo ha llevado a cabo un grupo de ingenieros y médicos en Munich, que han estudiado la composición de las imágenes de difusión en resonancia, mediante una gran base de datos de pacientes. Han intentado delimitar una suerte de relación estadística entre secuencias clásicas y difusión, delineando la curtosis, la dispersión de la relación entre las distintas imágenes. Mediante redes convolucionales, y basados en principios de anisotropía, han tallado un modelo que permite ayudar a predecir una imagen de difusión con bastante rendimiento, requiriendo menos data points, es decir menor censo de las señales por parte del equipo, lo que se traduce en menos tiempo de adquisición en el marco de una secuencia que alarga significativamente el estudio. Esto llevado a la práctica es un hecho no menor, si tenemos en cuenta tiempos de anestesia a los que deben someterse pacientes complejos, graves, que no cooperan; o incluso pacientes pediátricos. [9]

Uno de los conceptos tal vez más incomprensidos incluso

por los propios protagonistas en la radiología en general, es el del espacio k. Este refiere al conjunto de datos o información captada, que mediante un proceso matemático complejo (la transformada de Fourier), se deviene en forma estandarizada como resultado final, en una imagen contrastada en escala de grises. Hoy día existen trabajos que combinan los modelos de deep learning para el relleno y procesamiento del espacio k en resonancia magnética, mejorando la calidad de imagen y aumentando la velocidad de adquisición.

También dentro del campo de la optimización técnica de la imagen en resonancia, se encuentran procesos que basados en metodologías similares, intentan simular imágenes de 7 Tesla, obtenidas en equipos de 3 Tesla. [10] Otro concepto prometedor que implicaría a su vez un eventual desarrollo en TC, en forma análoga, es la transcripción de una fórmula cercana a la relación de no-linealidad entre las imágenes de un mismo estudio en baja y alta resolución. Equipos colaborativos entre universidades chinas y americanas, han logrado desarrollar un modelo acercado a una aproximación matemática de dicha relación. Utilizan modos que permiten mejorar los ruidos y artificios de las imágenes de baja resolución, con mejor rendimiento que técnicas convencionales. Inspirados en el uso protagónico de las redes convolucionales en el deep learning, éste modelo ha sido aplicado preferentemente a TC y ha arrojado como conclusión constituir un pilar conceptual importante para estimular los modelos en baja dosis. En este caso, no sólo contaríamos con la ventaja de mejorar una imagen potenciando los recursos técnicos y físicos disponibles; sino que también estaría el beneficio latente de evitar más cantidad de radiación innecesaria a los pacientes. [11]

## 3) Segmentación y detección de lesiones.

El leitmotiv del radiólogo gira en torno a la segmentación de estructuras anatómicas y delimitación de lesiones o aéreas patológicas. En el presente, las principales metas de la IA se encuentran volcadas y en pleno apogeo a que los sistemas comprendan las imágenes visualizadas de un estudio y diferencien lo sano de lo patológico. El deep learning se ha mostrado sumamente adecuado respecto a procesos en los que se le enseña a delinear una estructura anatómica normal o lesión, “dibujando” sus contornos digitalmente.


## APLICACIONES ACTUALES EN RADIOLOGÍA

### a) Detección de micro hemorragias y hemorragias cerebrales

Representa una de las tareas que por su frecuencia es muy relevante en el contexto de estudios de resonancias de cráneo, en pacientes con comorbilidades cardiovasculares o de otro tipo. Su detección, es un proceso laborioso realizado en forma manual por el radiólogo, que en el global, consume un tiempo no insignificante. Existen varios trabajos en la formación de herramientas que permitan la detección automática de hemorragias cerebrales, este

reviste de importancia, no solo en el auxilio diagnóstico al médico radiólogo; sino también como eventuales sistemas de “triage”, dónde al detectarse sangrados en forma automática se priorizaría la lectura del caso patológico en la cola de estudios.

Un estudio multidisciplinario chino, posee conclusiones positivas, respecto a un sistema creado para detección y cuantificación automática de microhemorragias que analiza los volúmenes de resonancia, mejorando por amplio margen la performance respecto a otros métodos asentados en análisis 2D. Se logró una alta sensibilidad de detección automática de microhemorragias, estipulada en 93.16%; con un promedio de apenas 2.74 falsos positivos por paciente. [12]



**Figura 5**

**Imágenes de resonancia magnética, cortes axiales:** se observa un gran hematoma intraparenquimatoso parieto-occipital, subcortical, izquierdo. Presenta densidad heterogénea a expensas de sectores dispuestos de distinta intensidad, en relación a sangrado en diferentes estadios. En la secuencia de susceptibilidad magnética (a derecha), se identifican múltiples lesiones de ‘pérdida de señal’, en ambos hemisferios, de disposición cortical, sustancia blanca y subependimaria. Estas imágenes si bien no patognomónicas, son altamente sugerentes de patrón de microsangrados por angiopatía amiloide, entidad característica de pacientes añosos que a menudo asocia hematomas lobares. Cortesía Dr. Matías Negrotto.

#### **b) Segmentación de lesiones isquémicas**

El objetivo de segmentación y detección de patología isquémica mediante IA, no debe considerarse livianamente supeditado a un mero juicio u “opinión” virtual. Es una herramienta que en su buen uso, mediante el adecuado aval de evidencia puede auxiliar la toma de decisiones terapéuticas. Se puede colaborar en el consenso de acciones, en terrenos que son muy laxos y que si bien tienen pautas y protocolos basados en evidencia, presentan al momento de acción; un amplio espectro de variabilidad interpersonal.

Se entrenaron redes convolucionales para predecir el resultado de uso de fibrinolíticos en el ACV agudo. Para ello, con una base de datos algo mayor a 200 pacientes con ACV agudo, se contrastó aquellos en los que se usó rTPA (84%) versus aquellos en los que no. Las redes fueron enseñadas para cada caso, con las imágenes en agudo de las resonancias en secuencias de difusión/ADC, FLAIR y mapas de perfusión. Se estudiaron las imágenes de cada paciente al momento de llegada a emergencia y en el control evolutivo, tanto en el grupo de pacientes que calificaron para revascularización endovenosa como en los pacientes que no. Lo que el modelo intenta, es predecir según la información visual que recaba, el tejido potencialmente salvable (área de penumbra) y el tejido que ya no será pasible de recuperación (área de infarto). [13]

Los resultados fueron muy prometedores, al demostrar que las redes convolucionales basadas en deep learning tienen una performance sustancialmente buena para predecir el volumen de infarto potencialmente reducido de mediar tratamiento con rTPA. Tal es así, que dicho trabajo, publicado en 2018 en la sección de stroke en el journal de la AHA (American Heart Association) representa uno de los puntales en el estado de arte de

los protocolos diagnósticos del ACV.

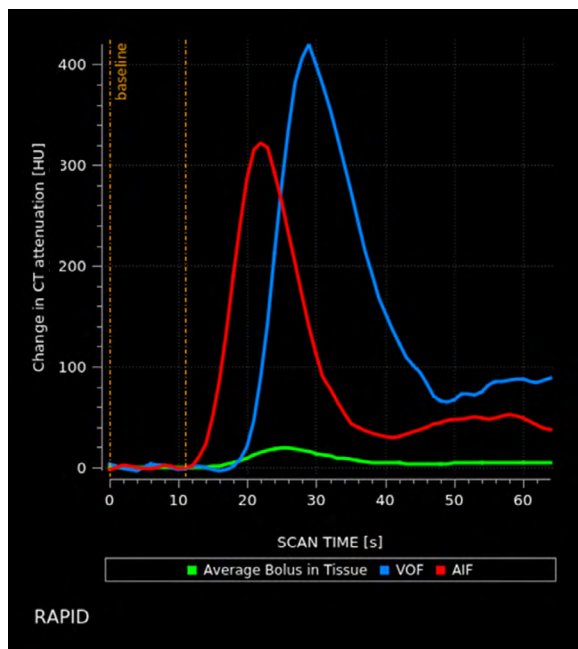
Se piensa que se podría avanzar algún paso más en virtud de la compleja calificación de los pacientes para revascularización en ACV agudo. Tener una herramienta que establezca con mayor certidumbre una predicción del beneficio de un tratamiento, permitiría solapar ambigüedades inter-observador y subjetividades más allá de la propia experiencia del médico tratante. No implicaría una sustitución per se, de los scores avalados por la evidencia ya existentes, sino más bien un afinamiento en su modalidad de aplicación.

#### **c) Segmentación tumoral y RADIOMICS**

Existen múltiples software que permiten segmentar las distintas estructuras de las imágenes digitales, ya sea en forma automática o manual. Los radiólogos pueden entrenar sistemas en el aprendizaje de estructuras anatómicas, sus variantes y lesiones.

La importancia de encontrar un sistema capaz de segmentar lesiones intraparenquimatosas radica en su utilidad diagnóstica, como eventual planificación quirúrgica y





**Figura 6**  
**Gráfico obtenido de una perfusión-TC mediante software 'RAPID' en paciente con stroke.**

Estos datos cuantificables son sustrato de procesamiento en los sistemas deep learning. En el eje de las ordenadas, vemos como aumenta y disminuye la densidad del parénquima en unidades Hounsfield a medida que en el eje de las abscisas, se representa el tiempo de pasaje del bolo de contraste. Las imágenes en conjunción con los datos escaneados a partir de una adquisición de perfusión son pasibles de recopilarse en modelos DL, de los cuales se pueden inferir estadísticas y generar modelos de predicciones a través de los controles.

control de respuesta.

Con la recopilación de los datos y el uso de IA, se han generado marcos de referencia para estimar la probabilidad de progresión lesional luego del tratamiento, con el fin de poder predecir un outcome que auxilie la toma de decisiones del equipo oncológico. [14]

Es importante destacar el papel de Radiomics para el estudio de lesiones en análisis de imágenes general. Podríamos definir Radiomics como el método que extrae información numérica de las imágenes médicas. Es una herramienta que permite trazar mapas a partir de una imagen, haciéndolos pasibles de análisis para procesados de Big Data. Es decir, una manera de caracterizar en forma cuantitativa y específica los fenotipos radiológicos.

Las imágenes están formadas una matriz que comprende una escala amplia de coordenadas e intensidades, donde se confieren texturas, a menudo no objetables por el ojo humano. Aquí radica el valor agregado del análisis numérico a partir de imágenes. Nos puede permitir no sólo mejorar nuestra precisión en diagnósticos; sino aportar mayor información, cuantificarla y abrir el horizonte diagnóstico. Aers y colegas, en 2014; realizaron el primer estudio a gran escala basado en Radiomics, a partir de cohortes de pacientes con tumores pulmonares y de la esfera otorrinolaringológica. Al analizar imágenes de tumores y su respuesta a tratamiento, pudieron coleccionar parámetros de texturas en la heterogeneidad intratumoral; que auxilian a predecir el outcome mediando tratamiento. [15]

También existen múltiples experiencias respecto a las lesiones encefálicas ocupantes de espacio, y precisamente los tumores, que tienen un espectro amplio de presentaciones; aún perteneciendo a una misma estirpe anatomopatológica. Cuando los tumores son de grados agresivos, poseen realce variable, bordes irregulares y una heterogeneidad de intensidades intrínseca que puede

estar supeditada a fenómenos patológicos como necrosis. Estos hechos determinan que en el global exista dificultad para una delimitación manual, aparte de ser una actividad que consume un tiempo significativo; ha demostrado presentar variabilidades no sólo en nivel interpersonal sino también intrapersonal. [16] El análisis de texturas y características imagenológicas mediante estas nuevas herramientas, permitirá ajustar, unificar y perfeccionar los diagnósticos y la formación de pronósticos. [17]

#### **d) Detección de nódulos pulmonares por IA y análisis automático de radiografías de tórax**

El cáncer pulmonar es la causa principal de muerte oncológica a nivel mundial. El manejo diagnóstico del nódulo pulmonar es un pilar fundamental en el escenario de su estudio. El sistema de servicios preventivos de Estados Unidos ha concluido con un nivel de evidencia B: la recomendación de realización de tomografía de tórax de baja dosis, como screening de cáncer pulmonar, en sujetos con factores de riesgo considerables. [18]

El problema estelar que está abordando la IA en este tema clásico de la radiología, es de intentar reducir los altos falsos positivos que se vinculan a los métodos convencionales. Hasta ahora, la cadena desencadenada de costos por estudios y pruebas diagnósticas (a veces invasivas) a las que llevan los falsos positivos; no ha logrado verter la balanza de riesgo/beneficio en favor de justificar con un nivel de evidencia universal qué población específica se beneficiaría del screening TC.


Si bien hoy día, y luego de años de discusión no existe consenso universal sobre en qué pacientes realizar TC de screening es probable que cada día aparezcan más protocolos con evidencias más robustas a favor de cuándo

estudiar pacientes asintomáticos. En la medida que más estudios de este tipo, se vuelquen a favor de la realización de TC de baja dosis, será un desafío para el trabajo cotidiano del radiólogo, puesto que aumentará significativamente el caudal de pacientes a estudiar.

La sensibilidad de algunos modelos entrenados con el data-set de LUNA Challenge, ha tenido resultados tan prometedores, estimados en una detección del 99.2%, con una especificidad de 99.1%. [19]

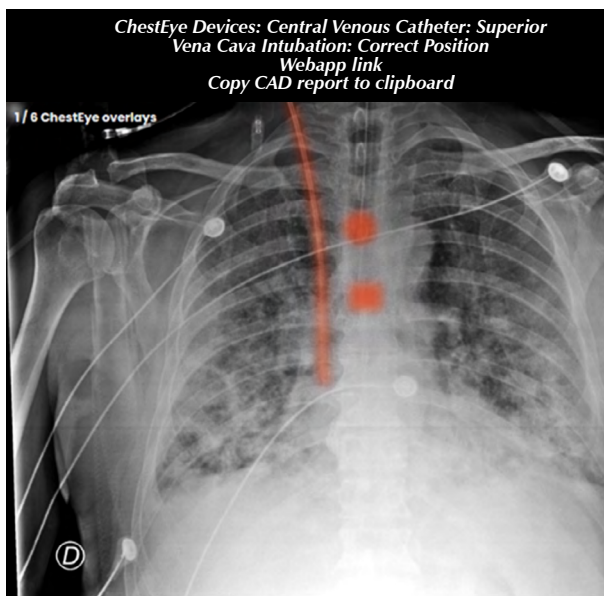
Aparte de los avances en el estudio tomográfico de tórax, existen múltiples modalidades de auxilio diagnóstico basado en IA, para radiografías de tórax. Están abocadas no sólo a la detección de patología pulmonar de valor para el informe del médico radiólogo; sino que van un paso más allá en la lectura, para el apoyo de situaciones cotidianas de las radiografías que se realizan en la urgencia y necesitan lectura inmediata del médico tratante. Muchos de estos programas están buscando validación de la FDA y ya poseen licencias en Unión Europea y otros países del mundo donde se permite su uso como auxilio diagnóstico complementario. Tal es el caso de la herramienta ChestEye que permite diagnosticar radiografías patológicas de tórax, mediante sistema de 'triage', donde las eventuales entidades urgentes se indican como alta prioridad (ejemplo: neumotórax) y patologías como nódulos pulmonares se etiquetarían como de mediana prioridad. Aparte de alteraciones, mediante mapas de calor, se segmentan en forma automática los dispositivos que puede poseer el paciente, como son catéteres de vía venosa central, intubación endotraqueal, cardiodesfibrilador, etc.

Estos avances en IA, relativos al análisis de técnicas de una imagen bidimensional, no volumétricas; como son las radiografías de tórax, por su relativa menor complejidad; se están utilizando en varios servicios del mundo y constituyen probablemente los primeros software con los que convivamos.



**Figura 7**

**Corte axial de tomografía de tórax** que evidencia nódulo pulmonar, sólido, subpleural, espiculado, de características sugestivas de agresividad, en paciente con un parénquima pulmonar enfisematoso. La histopatología fue compatible con adenocarcinoma (ex carcinoma bronquiolo-alveolar). Estos nódulos, según su tamaño y características radiológicas, serían altamente pasibles de ser detectados en forma automático por sistemas de IA (con rendimiento cercano a 100%). El desafío real de la IA, se encuentra en aquellos nódulos de tamaños más pequeños y con características menos prominentes para orientarse a baja o alta agresividad.



**Figura 8**

**Radiografía de tórax**, enfoque de frente; realizada en cama, de paciente en cuidados intensivos Sanatorio COMECA, ciudad de Canelones. Análisis mediante herramienta "ChestEye Devices" basada en IA. Se delimita en mapa de calor en rojo, la proyección del catéter de vía venosa central; así como el tubo de intubación endotraqueal, en este caso correctamente colocados.

#### e) Inteligencia artificial en imagenología mamaria

La imagenología mamaria es una subespecialidad con primordial uso de screening, aunque en este caso, a escala universal; es por ello, que también cobra relevancia el auxilio diagnóstico mediante inteligencia artificial. Décadas atrás, el CAD (software Image Checker M1000) emergió en como el primer sistema de un auxilio electrónico asistencial, no basado en IA, para el reconocimiento de patrones lesionales.

Con el auge de la tomosíntesis, sistemas específicos de CAD basados en deep learning (iCAD) han vuelto a emerger, y también se planean en otras técnicas como

resonancia magnética y ecografía mamaria. [33]

Al margen de los múltiples avances, una revisión de Clinical Radiology de mayo de 2019, considera que aún es temprano para esbozar conclusiones en esta área puntual. Se necesitarán evidencias muy potentes que avalen el costo-beneficio puesto que nos encontramos en un escenario de primordial interés en salud pública. Se requerirán trabajos poblacionales basados en enormes sets de datos y que permitan cumplir la aplicación de IA según las normativas del reglamento general de protección de datos de la Unión Europea. [20]

### CONCLUSIONES ACERCA DEL USO DE DEEP LEARNING EN RADIOLOGÍA

Si bien, en informática es difícil especular sobre el impacto a largo plazo de los desarrollos digitales en el trabajo humano; sí se puede establecer con cercana exactitud a corto o mediano plazo. Las posturas fatalistas que surgen del seno de la radiología, respecto al deep learning y sus avances, nacen de la amenaza implícita que sugiere, (como todo avance de la era digital) la suplantación del hombre por la máquina. Si bien es muy improbable, o al menos estamos lejos, de la suplantación del radiólogo por sistemas basados en IA; se piensa que en un no muy largo plazo, los radiólogos que conozcan y sepan utilizar IA sustituirán a los que no.

Transitamos el inicio de una encrucijada en la radiología. Con el avance vertiginoso en técnicas diagnósticas, el futuro de nuestra labor parece encaminado a la detección meticulosa que ofrecen los avances tecnológicos. Pero es preciso entender que paradójicamente ese terreno de la detección, es donde seremos más susceptibles a aplicación de la IA.

Un hecho no menor, respecto al rápido desarrollo de IA en radiología está basado en la buena disponibilidad de acceso a herramientas informáticas y la gratuidad a la que están sujetas muchas plataformas. Sería impensado en otras escalas de la medicina contar con los materiales para empezar a desarrollar, investigar o producir, sin la sobrecotización que usualmente se le achaca al terreno médico. La radiología, siendo una disciplina a medio camino de otros terrenos, puede beneficiarse en gran forma de su posición, al obtener de un arquetipo ajeno al mundo médico como es el campo de la tecnología informática; los principios que ordinariamente lo rigen como son el valor de la gratuidad y el carácter colaborativo. Se podría pensar que en esta suerte de democratización del conocimiento, entendemos que cobra relevancia el poder de desarrollo de los países pequeños. [21]

Si bien las universidades de Norteamérica y Europa occidental han demostrado estar a la vanguardia de los grandes progresos del campo, China se posiciona con un número no menor de desafíos logrados y galardones en el campo del reconocimiento visual. Israel, ha sido una de las naciones que más startups ha postulado en las distintas exposiciones mundiales de IA aplicadas a radiología, ocupando un lugar especial en el evento estelar organizado a manos de la Sociedad Radiológica de Norteamérica (RSNA). Sorprendente de ver el caso de Tel-Aviv, una ciudad en población comparable a Montevideo con más proyectos que grandes países Europa sumados. Es interesante entender desde esta perspectiva el rol que podría intentar seguir Uruguay en su posición de pequeña economía emergente, cuya brecha en investigación no ha hecho más que quedar relegada frente a potencias desarrolladas en épocas de medicina basada en evidencia.

En el proceso evolutivo de la inteligencia artificial y su inevitable futura convivencia con la imagenología; deberán ser los radiólogos quienes aprendan a respaldarse con estas técnicas para aumentar su productividad. Siendo la verdadera amenaza permanecer al margen de dichos desarrollos que permitirán optimizar los flujos de trabajo y mejorar la calidad en la atención del paciente.

Agradecemos al Prof. Dr. Luis Dibarboure, por el apoyo brindado.

## BIBLIOGRAFÍA

- 1) Paiva OA, Prevedello LM. The potential impact of artificial intelligence in radiology. *Radiologia brasileira*. doi:10.1590/0100-3984.2017.50.5e1
- 2) Chang, P. What to make of the increased hype surrounding AI in radiology [Internet]. *Radiology Business*. De: <https://www.radiologybusiness.com/sponsored/9667/topics/imaging-informatics/rsna-2018-hype-ai-radiology-paul-chang>. 2018. Febles, G. Inteligencia artificial en radiología, revisión de conceptos, aplicaciones y consecuencias. <http://sriuy.org.uy/ojs/index.php/Rdi/article/view/53>
- 3) Zaharchuk G, Gong E, M. Wintermark, M. Deep Learning in Neuroradiology. *Am. J. Neuroradiol*, October 2018, 39 (10) 1776-1784. <https://doi.org/10.3174/ajnr.A5543>
- 4) Krizhevsky A, Sutskever I, Hinton G E. "Imagenet classification with deep convolutional neural networks. <https://dl.acm.org/doi/10.5555/2999134.2999257>.
- 5) Deshpande, A. The 9 Deep Learning Papers You Need To Know About (Understanding CNNs)". *Engineering at forward*. Retrieved 2018-12-04. <https://adeshpande3.github.io/The-9-Deep-Learning-Papers-You-Need-To-Know-About.html>
- 6) Hahnloser RH, Sarpeshkar R, Mahowald MA, Douglas RJ, Seung HS. Digital selection and analogue amplification coexist in a cortex-inspired silicon circuit. *Nature*. 2000 Jun 22;405(6789):947-51. doi: 10.1038/35016072.
- 7) McDonald C. Costs functions and gradient descents. *Machine Learning Fundamentals*. De: <https://towardsdatascience.com/machine-learning-fundamentals-ii-neural-networksf1e7b2cb3eef>
- 8) Golkov V, Dosovitskiy A, Sperl JJ, et al. Q-space deep learning: twelve-fold shorter and model-free diffusion MRI scans. *Med Imaging* 2016; 35:1344–51.
- 9) Wang S, Su Z, Ying L, et al. Accelerating Magnetic Resonance Imaging via deep learning. *Proc IEEE Int Symp Biomed Imaging*. 2016 Apr;2016:514-517. doi: 10.1109/ISBI.2016.7493320.
- 10) Bahrami K, Shi F, Zong X. Reconstruction of 7T-like images from 3T. MRI. *IEEE Trans Med Imaging* 2016; 35:2085–97.
- 11) Qi D, Hao C, Lequan Y. Automatic Detection of Cerebral Microbleeds From MR Images via 3D Convolutional Neural Networks. *IEEE Transactions on Medical Imaging*, May 2016,35(5):1. doi:10.1109/TMI.2016.25281291
- 12) G. Zaharchuk, E. Gong, M. Wintermark, D. Deep Learning in Neuroradiology. *American Journal of Neuroradiology* October 2018, 39 (10) 1776-1784; doi: <https://doi.org/10.3174/ajnr.A5543>
- 13) Maier O, Schröder C, Forkert ND, Martinetz T, et al. Classifiers for Ischemic Stroke Lesion Segmentation: A Comparison Study. *Plos one*. 2015;10(12):e0145118. DOI: 10.1371/journal.pone.0145118.
- 14) Aerts HJ, Velazquez ER, Leijenaar RT, Parmar C, Grossmann P, Carvalho S, Bussink J, Monshouwer R, Haibe-Kains B, Rietveld D, et al. (2014). "Decoding tumour phenotype by noninvasive imaging using a quantitative radiomics approach". *Nat Commun*. 5: 4006. Bibcode:2014NatCo 5.4006A. doi:10.1038
- 15) Nielsen A, Mouridsen K, Hansen M. y. Deep learning: utilizing the potential in data bases to predict individual outcome in acute stroke. De: *Proceedings of the Annual Meeting of the International Society for Magnetic Resonance in Medicine, Honolulu, Hawaii*. April 22-27, 2017; 5665.
- 16) Wachinger C, Reuter M, Klein T. DeepNAT: Deep convolutional neural network for segmenting neuroanatomy. *Neuroimage*. 2018 Apr 15;170:434-445. doi: 10.1016/j.neuroimage.2017.02.035.
- 17) Humphrey L., Deffebach M., Pappas MA. (2013) Screening for Lung Cancer: Systematic Review to Update the U.S. Preventive Services Task Force Recommendation. *Evidence Synthesis*. N0. 105
- 18) Isa A. Gregory R. Gowthaman G. Lung Nodule Detection via Deep Reinforcement Learning. *Frontiers in Oncology* 2018 Apr 16. doi: 10.3389/fonc.2018.00108
- 19) Le EPV, Wang Y, Huang Y, Hickman S, Gilbert FJ. Artificial intelligence in breast imaging. *Clin Radiol*. 2019 May;74(5):357-366. doi: 10.1016/j.crad.2019.02.006.
- 20) Chartrand G, Cheng PM, Vorontsov E, Drozdal M, Turcotte S, Pal CJ, Kadoury S, Tang A. Deep Learning: A Primer for Radiologists. *Radiographics*. 2017 Nov-Dec;37(7):2113-2131. doi: 10.1148/rg.2017170077.