Eficiencia del aprendizaje supervisado aplicado a la clasificación de tomografías computarizadas para el diagnóstico de COVID-19

Lorena Brazeiro[1], Constanza Vásquez[2],
Natalia Garay[3] and Franco Simini[3]

[1]*Estudiante del XXXII Seminario de Ingeniería Biomédica 2023.*
[2]*Conferencista del Seminario del día 06 de junio de título "AI en imágenes médicas", Asistente de Investigación y Desarrollo SCIAN, Lab UChile*
[3]*Docentes del XXXII Seminario de Ingeniería Biomédica 2023.*

***Resumen*— En este trabajo se pretende estudiar la eficiencia del aprendizaje supervisado en la detección de COVID-19, utilizando tomografías computarizadas. Esta técnica imagenológica es muy útil como apoyo al diagnóstico médico cuando los tiempos de respuesta y diagnóstico son relevantes y los recursos humanos y materiales no son suficientes.**

De acuerdo a lo analizado en este trabajo, los artículos estudiados evidencian que los resultados son muy prometedores, sin embargo, es importante destacar que el análisis realizado se llevó a cabo con un número muy limitado de artículos. Para poder generalizar estos resultados y evaluar su rendimiento, sería importante realizar un análisis más amplio donde además se tenga en cuenta las diferentes poblaciones y contextos clínicos.

Introducción

El COVID-19 ha afectado a un porcentaje muy elevado de la población mundial, debido a que es una enfermedad altamente contagiosa que incluso puede producir la muerte. Dicha enfermedad hizo colapsar los sistemas de salud de varios países [1].

La reacción en cadena de la polimerasa de transcripción inversa (RT-PCR) es considerado el estándar para el diagnóstico de COVID-19, sin embargo, la falta de recursos y los estrictos requisitos del entorno de prueba, restringen la detección rápida y eficaz de casos sospechosos. Además, la inspección de RT-PCR también experimenta en algunos casos, tasas de falsos negativos [2] y no es posible predecir el progreso de la enfermedad. Esto hace que sea necesario disponer además, de otras soluciones, como puede ser el uso de la Inteligencia Artificial (IA).

En este trabajo se investiga la inteligencia artificial aplicada a la medicina, específicamente en imágenes médicas para su posible detección de casos de COVID-19

Fundamentos de la IA.

La Inteligencia Artificial es la capacidad de sistemas y programas informáticos de usar algoritmos, aprender de los datos y utilizar lo aprendido para realizar tareas que normalmente requerirían de la inteligencia humana. A diferencia de los humanos, los dispositivos basados en IA analizan grandes volúmenes de información de forma simultánea. Son capaces de aprender y tomar decisiones[3].

Como se muestra en la figura 1, dentro de la IA se encuentran el Machine Learning (aprendizaje automático) y dentro del Machine Learning existe un subcampo que es el Deep Learning (aprendizaje profundo).

El Machine Learning (ML) se puede definir como el campo de estudio que da a los computadores la capacidad de aprender sin ser programados de manera explícita [4] .

El Deep Learning (DL) permite a las computadoras construir conceptos complejos a partir de conceptos más simples [5]. El mismo está basado en las Redes Neuronales Artificiales (RNA) organizadas en capas. Una RNA en ML, se diferencia en la cantidad de capas ocultas, una RNA en ML típicamente tiene una capa oculta, pero una RNA de DL puede tener cientos de capas ocultas, cada una con varias unidades de procesamiento distintas (neuronas) [4].

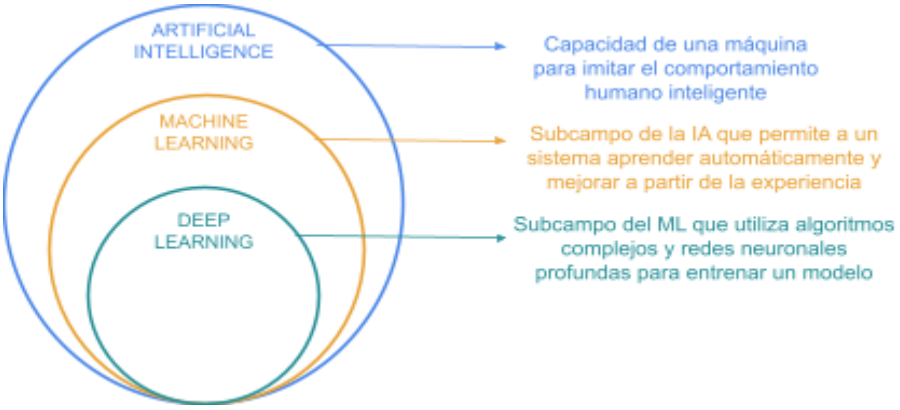

fig. 1: Inteligencia artificial, sus subcampos y características principales

De acuerdo con el problema que se desee resolver, tenemos 3 enfoques distintos dentro del ML que pueden utilizarse: aprendizaje supervisado, no supervisado y por refuerzo.

En el Aprendizaje Supervisado, los algoritmos utilizan datos que han sido etiquetados u organizados previamente para indicar cómo tendría que ser categorizada la nueva información. Este método requiere la intervención humana para proporcionar retroalimentación[3].

Dentro de los algoritmos de aprendizaje supervisado, tenemos principalmente dos categorías: Clasificación y Regresión. En la tarea de clasificación, se solicita al programa que especifique a qué categoría pertenece una determinada entrada entre k categorías.

En la regresión se solicita al programa que prediga un valor numérico, dado una entrada determinada[5].

En el Aprendizaje No Supervisado, los algoritmos no usan ningún dato etiquetado u organizado previamente para indicar cómo tendría que ser categorizada la nueva información, sino que deben encontrar la forma de clasificarlas ellos mismos. Este método no requiere la intervención humana.[3].

El Aprendizaje por Refuerzo, los algoritmos aprenden de la experiencia. Es decir, tenemos que darles «un refuerzo positivo» cada vez que aciertan. La forma en que estos algoritmos aprenden se puede comparar con la de los perros cuando les damos «recompensas» por ejemplo, al aprender a sentarse [3].

Aplicaciones del Machine Learning en la medicina.

El Machine Learning tiene aplicaciones en diversas ramas de la medicina, entre ellas se destacan el diagnóstico médico, el cual puede utilizarse como apoyo, guiando al médico en el proceso y sugiriendo incluso enfermedades raras, que por diferentes razones podría no tenerlas en cuenta a la hora de diagnosticar [6] .

En particular se ha encontrado ampliamente útil en el diagnóstico de imágenes médicas, dado que por ejemplo puede predecir si es un cáncer de mama es maligno o benigno [7], si una persona tiene o no COVID-19 [8], categorizar las lesiones producidas por COVID-19 [1] , el grado de osteoartrosis de rodilla [9] , etc.

Otras de las aplicaciones es la prevención de enfermedades, ya que es capaz de brindar un diagnóstico precoz en enfermedades como el cáncer, cardiopatías, riesgo de depresión, etc [6]. También es útil en la prognosis, por

ejemplo, al ser capaz de predecir la reacción de una persona ante un determinado tratamiento, o detectar la progresión de la enfermedad de parkinson [6] y de esta forma saber cuál puede ser el mejor camino a tomar.

La Medicina personalizada es otras de sus aplicaciones y es útil para poder brindar un tratamiento adecuado a cada persona, como en la prevención de caries [10], etc

Otra utilidad se da en el desarrollo de fármacos, donde en la actualidad hay empresas de la salud que están usando redes profundas y generativas para desarrollar sus medicamentos [11].

Imágenes médicas.

Una imagen es la forma discreta de un fenómeno continuo, obtenida tras captura o generación de puntos distribuidos espacialmente. Las mismas están casi siempre representadas como tablas de valores dispuestas en filas y columnas. Tal representación facilita el uso de la geometría vectorial y del álgebra de matrices para crear modelos matemáticos y algoritmos. Al ser discreta, puede ser procesada en un entorno digital, por lo tanto, hay adecuación inmediata entre la imagen y la computación, lo que privilegia la imagen como herramienta de entendimiento. [12]

El aporte de la imagen a la ciencia del diagnóstico médico es fundamental. Para que las imágenes médicas puedan cumplir con la función de diagnóstico, es imperativo garantizar su calidad y reproducibilidad.

Del lado de la imagen médica, la reproducción fiel del color no es de importancia, ya que los valores se representan en una escala de grises, esencialmente porque los valores capturados no pertenecen al espectro visible. Hay diferentes modalidades para obtener imágenes médicas, algunas de ellas son las tomografías computarizadas donde se mide la densidad o atenuación de rayos X, resonancias magnéticas donde se mide la intensidad del campo, ecografías donde se miden las ondas de sonido, y las PET donde se mide la radiación por emisión de positrones. [12]

Imágenes y Machine Learning

La clasificación de imágenes es un problema supervisado de clasificación.

La misma consiste en asignar a cada imagen de entrada una probabilidad de clase de salida, (por ejemplo tumor benigno, tumor maligno), que mejor se ajuste a la imagen. Para los humanos, esta tarea de reconocimiento es una de las primeras habilidades que aprendemos.

Cuando un ordenador toma una imagen como entrada, ve una matriz de píxeles. La idea es que al dar a la red neuronal esta matriz de números, su salida sea la probabilidad de que la imagen pertenezca a una clase determinada (por ejemplo 0,80 benigno, 0.20 maligno).

Se pretende que el algoritmo diferencie entre todas las imágenes dadas, y encuentre cuáles son las características únicas que definen un tumor benigno, y cuáles definen un tumor maligno [13].

Redes neuronales convolucionales (CNNs, Convolutional Neural Networks)

Al tratar con clasificación de imágenes, el tipo apropiado de red que debe utilizarse son las redes neuronales convolucionales (CNNs, Convolutional Neural Networks)[13].

El diseño de las redes neuronales convolucionales toma inspiración de la corteza visual humana, la zona del cerebro que procesa la entrada visual[14].

El nombre "red neuronal convolucional" indica que la red utiliza una operación matemática llamada convolución, (la cual es del tipo lineal) en lugar de la multiplicación general de matrices.

Una capa típica de una red convolucional consta de tres etapas. En la primera etapa, la capa realiza varias convoluciones en paralelo, para producir un conjunto de activaciones lineales y extraer las características más básicas. En la segunda etapa, cada activación lineal se pasa a través de una función de activación no lineal, la cual se encarga de extraer características más complejas. En la tercer etapa, utiliza una función de agrupamiento (pooling) [5] la cual se encarga de reducir el flujo de datos obtenido de las capas anteriores, extrayendo las características más importante de la imagen y reducir la carga computacional que va a tener la CNN, ayudando a que la red se entrene, ya que la imagen resultante va a ser más pequeña que la original, conteniendo sus principales características[14].

Además al final de la red se encuentra una capa de clasificación, generalmente compuesta por una capa flatten, una o más capas densas (fully connected) y una softmax que es la encargada de entregar la probabilidad de cada clase [5] [14] como se puede ver en la fig. 2.

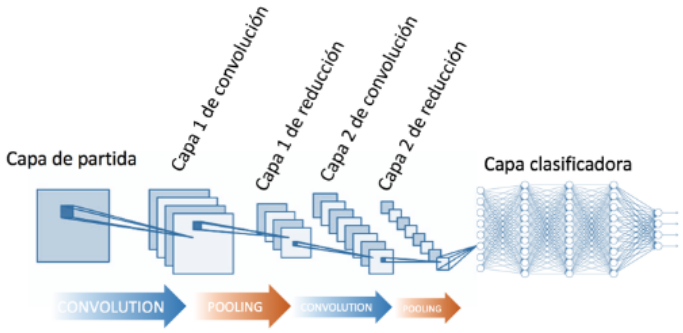

fig. 2:Etapas de procesamiento en una red neuronal convolucional tomado de Santamaria, Lemuz et.al [15]

Caso de análisis:

Se estudian algunos artículos publicados orientados a la detección de COVID-19, utilizando Deep Learning y tomografías computarizadas. Para ello se realiza una descripción general de la metodología y entrenamiento de los modelos supervisados utilizados en estos casos.

Generalmente, los sistemas basados en Deep Learning se componen de varios pasos, como la recopilación de datos, la preparación de datos, la extracción y clasificación de características y la evaluación del rendimiento.

En la fig. 3 se ilustra el proceso general de un sistema de diagnóstico de COVID-19 basado en Deep Learning e imágenes. En la etapa de recolección de datos, se considera como participante a los pacientes de hospitales. Para el diagnóstico de COVID-19, en este caso se toman muestras de tomografía computarizada. El siguiente paso necesario es la preparación de datos que convierte los mismos en un formato apropiado. En este paso, el preprocesamiento de datos incluye algunas operaciones como eliminación de ruido, cambio de tamaño, aumento de datos, etc. El paso de partición de datos divide los mismos en conjuntos de entrenamiento, validación y prueba para el experimento. Los datos de entrenamiento se utilizan para desarrollar un modelo particular que se evalúa mediante datos de validación, y el rendimiento del modelo desarrollado se evalúa mediante datos de prueba. El paso principal del diagnóstico de COVID-19 basado en el Deep Learning es la extracción y clasificación de características. En esta etapa, la técnica de aprendizaje profundo extrae automáticamente las características realizando varias operaciones repetidamente y finalmente, la clasificación se realiza en función de las etiquetas de clase (Sin COVID-19 o con COVID-19). Por último, el sistema desarrollado se evalúa mediante algunas métricas de evaluación como precisión, sensibilidad, especificidad, precisión y puntaje F1[2].

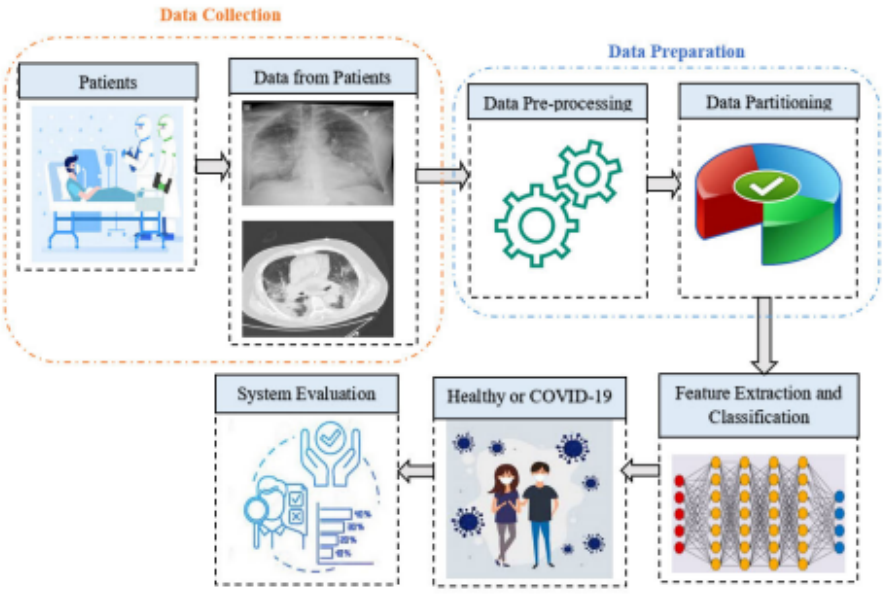

fig. 3: Proceso general del sistema de diagnóstico COVID-19 basado en aprendizaje profundo tomado de Md. Milon Islam et al.[2]

Para lograr resultados en el diagnóstico de COVID-19 mediante Deep Learning, se aplicaron dos técnicas: modelos pre entrenados con aprendizaje de transferencia profunda como pueden ser ResNet, VGG, GoogleNet y técnicas de aprendizaje profundo personalizados.

TABLA I

RESUMEN DEL DIAGNÓSTICO DE COVID-19 BASADO EN ML EN IMÁGENES DE TOMOGRAFÍA COMPUTARIZADA(TC)

Autores	Fuentes	Número de Imágenes	Número de Clases	Particionamiento	Técnicas	Performances(%)
Ardakani et al. [16]	Datos en tiempo real del ambiente hospitalario	1020(COVID-19=510, no COVID-19=510)	2(COVID-19, No COVID-19)	Entrenamiento=80 % Validación=20%	AlexNet, VGG-16, VGG-19, SqueezeNet, GoogleNet, MobileNet-V2, ResNet-18, ResNet-50, **ResNet-101,** Xception.	Sensibilidad=100%, Especificidad=99,02% Exactitud=99,51% AUC=99,4%
Ying et al. [17]	Dos hospitales de China	1990 (COVID-19 =777, no COVID-19= 708, Neumonía Bacteriana= 505)	3(COVID-19, No COVID-19, Neumonia Bacteriana)	Entrenamiento=60 % Validación=10% Testing=30%	DRE-Net	Sensibilidad=92.6%, Especificidad=95.8% Exactitud=94.1%, Precisión=96.1%, AUC=99 %
Penissi et al. [1]	Única fuente	166(COVID -19=72, no COVID-19= 94)	2(COVID-19, No COVID-19)	Entrenamiento=57 % Validación=6% Testing=37%	AlexNet, ResNet-18, ResNet-34, ResNet-50, ResNet-101, ResNet-152, DenseNet-121 DenseNet-169 **DenseNet-201,** SqueezeNet, ResNeXt	Sensibilidad=90.3%, Especificidad=93.5% Exactitud=91.9

Ardakani et al. propuso un sistema para la detección de COVID-19 utilizando diez variantes de técnicas CNN en imágenes de TC. Las variantes utilizadas para el diagnóstico son AlexNet, VGG-16, VGG-19, SqueezeNet, GoogleNet, MobileNet-V2, ResNet-18, ResNet-50, ResNet-101 y Xception. En el sistema propuesto se consideran un total de 1020 muestras de TC de los casos de COVID-19 y no COVID-19, adquiridas en el hospital universitario de Irán. El conjunto de datos se divide en conjunto de entrenamiento y validación en una proporción de 80% y 20% respectivamente. Entre las 10 redes, ResNet-101 y Xception se desempeñaron comparativamente mejor que las demás, donde ResNet-101 obtuvo una exactitud del 99,51 %, una sensibilidad del 100 %, un AUC del 99,4 % y una especificidad del 99,02 % como se puede ver en la tabla I. En otra red, Xception encontró una exactitud, sensibilidad, AUC y especificidad del 99,02 %, 98,04 %, 87,3 % y 100 %, respectivamente [16] .

En otro estudio, Ying et al. introdujo una técnica de aprendizaje profundo basada en la red neuronal de extracción de relaciones detalladas (DRE-Net) denominada DeepPneumonia para el diagnóstico de casos de COVID-19 utilizando imágenes de TC. El sistema propuesto se desarrolla con la combinación de ResNet50 y Feature Pyramid Network (permite extraer las mejores características de cada muestra). El conjunto de datos se

recopiló de dos hospitales populares en China. En este sistema, se tomaron un total de 1990 cortes de imágenes donde 777 imágenes para COVID-19, 505 cortes para neumonía bacteriana y 708 muestras de personas normales. El conjunto de datos se divide en una proporción de 60 %, 30 % y 10 % para el conjunto de entrenamiento, prueba y validación, respectivamente. El sistema propuesto obtuvo una exactitud del 94.1 %, una sensibilidad del 92.6 %, una precisión del 96.1 %, una especificidad del 95.8% y un AUC del 99 %[17].

Por otra parte, Penissi et al. propuso un sistema para la detección automatizada de COVID-19 utilizando 11 variantes de técnicas CNN en imágenes de TC. Las variantes utilizadas para el diagnóstico son AlexNet, ResNet-18, ResNet-34, ResNet-50, ResNet-101, ResNet-152, DenseNet, SqueezeNet y ResNeXt. En el sistema propuesto se consideran un total de 166 TC de los casos de COVID-19 (positividad confirmada tanto por un RT-PCR, como por una prueba de anticuerpos IgG o IgM) y no COVID-19. El conjunto de datos se divide en 57% de entrenamiento, 6% de validación y 37% utilizado para test. Entre las 11 redes, DensNet 201 se desempeñó comparativamente mejor que las demás obteniendo una sensibilidad del 90.3 %, una exactitud del 91.9 % y una especificidad del 93.5 % [1].

DISCUSIÓN y CONCLUSIÓN

Hay artículos que evidencian la existencia de técnicas de inteligencia artificial con la sensibilidad y especificidad necesarias para ayudar al clínico en el diagnóstico de enfermedades. Como se analizó en este trabajo, los resultados obtenidos para el diagnóstico de COVID-19 son prometedores y comparables con la sensibilidad del RT-PCR [18]. En particular, en el contexto del COVID-19, varios autores han avanzado en el análisis de IA en combinación con las TC, para categorizar las lesiones pulmonares producidas por COVID-19 y de esta manera obtener información del avance de la enfermedad[1][17]. Esto no es posible determinarlo con el uso exclusivo del RT-PCR.

Por otra parte, en caso de que no sea posible utilizar imágenes de TC para el diagnóstico de COVID-19, es posible recurrir a la radiografía de tórax (CXR) la cual es más rápida, económica y se encuentra ampliamente disponible en los centros de salud. Dicha fuente, en conjunto con las técnicas de Deep Learning expuestas y variaciones de las mismas, también han logrado muy buenos resultados[2] [8]. No obstante, cuando ambas están disponibles, se prefiere la detección por TC en comparación con los rayos X, debido a su versatilidad. y vista pulmonar tridimensional [2].

Referencias

.

[1] M. Pennisi et al., «An explainable AI system for automated COVID-19 assessment and lesion categorization from CT-scans», Artif. Intell. Med., vol. 118, p. 102114, ago. 2021, doi: 10.1016/j.artmed.2021.102114.

[2] Md. M. Islam, F. Karray, R. Alhajj, y J. Zeng, «A Review on Deep Learning Techniques for the Diagnosis of Novel Coronavirus (COVID-19)», IEEE Access, vol. 9, pp. 30551-30572, 2021, doi: 10.1109/ACCESS.2021.3058537.

[3] L. Rouhiainen, «Inteligencia artificial», Madr. Alienta Editor., 2018.

[4] J. DÃ\-az-RamÃ\-rez, «Aprendizaje AutomÃ!`tico y Aprendizaje Profundo», Ingeniare Rev. Chil. Ing.-A, vol. 29, pp. 180-181, jun. 2021.

[5] I. Goodfellow, Y. Bengio, y A. Courville, Deep learning. MIT press, 2016.

[6] J. F. Ávila-Tomás, M. A. Mayer-Pujadas, y V. J. Quesada-Varela, «La inteligencia artificial y sus aplicaciones en medicina II: importancia actual y aplicaciones prácticas», Aten. Primaria, vol. 53, n.o 1, pp. 81-88, ene. 2021, doi: 10.1016/j.aprim.2020.04.014.

[7] A. Akselrod-Ballin et al., «Predicting Breast Cancer by Applying Deep Learning to Linked Health Records and Mammograms», Radiology, vol. 292, n.o 2, pp. 331-342, ago. 2019, doi: 10.1148/radiol.2019182622.

[8] R. G. Babukarthik, V. A. K. Adiga, G. Sambasivam, D. Chandramohan, y J. Amudhavel, «Prediction of COVID-19 Using Genetic Deep Learning Convolutional Neural Network (GDCNN)», IEEE Access, vol. 8, pp. 177647-177666, 2020, doi: 10.1109/ACCESS.2020.3025164.

[9] M. A. O. Huichaqueo, «Aprendizaje supervisado en detección de osteoartritis de rodilla a partir de imágenes de resonancia magnética».

[10] I.-A. Kang, S. Ngnamsie Njimbouom, K.-O. Lee, y J.-D. Kim, «DCP: Prediction of Dental Caries Using Machine Learning in Personalized Medicine», Appl. Sci., vol. 12, n.o 6, p. 3043, mar. 2022, doi: 10.3390/app12063043.

[11] Y. Li, J. Pei, y L. Lai, «Structure-based de novo drug design using 3D deep generative models», Chem. Sci., vol. 12, n.o 41, pp. 13664-13675, 2021, doi: 10.1039/D1SC04444C.

[12] F. Simini, Ed., Ingeniería biomédica: perspectivas desde el Uruguay, 1. ed. Montevideo: NIB, Núcleo de Ingeniería Biomédica de las Fac. de Medicina e Ingeniería, Univ. de la República Oriental del Uruguay, 2007.

[13] A. Ferreras Extremo, «Estudio de algoritmos de redes neuronales convolucionales en dataset de imágenes médicas», 2021, [En línea]. Disponible en: https://uvadoc.uva.es/handle/10324/47137

[14] F. Lubinus Badillo, C. A. Rueda Hernández, B. Marconi Narváez, y Y. E. Arias Trillos, «Redes neuronales convolucionales: un modelo de Deep Learning en imágenes diagnósticas. Revisión de tema», Rev. Colomb. Radiol., vol. 32, n.o 3, pp. 5591-5599, sep. 2021, doi: 10.53903/01212095.161.

[15] L. SANTAMARIA y R. LEMUZ, «Reconocimiento de tejido tumoral en imágenes de resonancia magnética por medio de una red neuronal convolucional», Fac. Cienc. Comput., pp. 1-1, 2018.

[16] A. A. Ardakani, A. R. Kanafi, U. R. Acharya, N. Khadem, y A. Mohammadi, «Application of deep learning technique to manage COVID-19 in routine clinical practice using CT images: Results of 10 convolutional neural networks», Comput. Biol. Med., vol. 121, p. 103795, jun. 2020, doi: 10.1016/j.compbiomed.2020.103795.

[17] Song Ying et al., «Deep learning Enables Accurate Diagnosis of Novel Coronavirus (COVID-19) with CT images», medRxiv, p. 2020.02.23.20026930, ene. 2020, doi: 10.1101/2020.02.23.20026930.

[18] C. Long et al., «Diagnosis of the Coronavirus disease (COVID-19): rRT-PCR or CT?», Eur. J. Radiol., vol. 126, p. 108961, may 2020, doi: 10.1016/j.ejrad.2020.108961.