

Artículo de Revisión

DETECCIÓN DE COVID-19 A PARTIR DE IMÁGENES RADIOGRÁFICAS UTILIZANDO REDES NEURONALES CONVOLUCIONALES: UNA REVISIÓN BIBLIOGRÁFICA

DETECTION OF COVID-19 FROM RADIOGRAPHIC IMAGES USING CONVOLUTIONAL NEURAL NETWORKS: A BIBLIOGRAPHICAL REVIEW

YAN AN CORNEJO MONTOYA¹

 <https://orcid.org/0000-0003-0373-1581>

SOFÍA ALEJANDRA GARCÍA CORNEJO²

 <https://orcid.org/0000-0002-4961-2206>

Recibido: 02/06/2022

Aceptado: 16/06/2022

Publicado: 11/07/2022

^{1,2} Universidad Católica Santiago de Guayaquil, Guayaquil, Ecuador

E-mail: ¹yanornejo@yahoo.com, ²sagc2298@gmail.com



Resumen

La crisis generada en el planeta por la COVID-19 (SARS-CoV-2) ocasionó un efecto devastador a nivel mundial y por tal razón se necesitó una detección eficaz de los posibles contagios de los pacientes infectados. En tal sentido, el presente trabajo recopila información de herramientas de diagnóstico que utilizan Deep Learning (DL) en imágenes médicas para detectar COVID-19. Es un estudio observacional descriptivo. Además, el propósito es analizar y comparar como el DL aplicado a imágenes radiográficas optimiza recursos y manejo de resultados de manera objetiva y oportuna, evidenciando una cooperación favorable entre sector sanitario, institucional y tecnológico. De esta manera, las Redes Neuronales Convolucionales (CNN), en sus diferentes algoritmos, son la arquitectura elegida en el área biomédica para el diagnóstico de enfermedades aplicadas al análisis de imágenes radiográficas, cuya finalidad es ayudar al servicio médico en aligerar la atención de pacientes con una detección temprana de síntomas y factores de riesgo del virus COVID-19, debido a la cantidad de pacientes sintomáticos y asintomáticos. Los resultados de esta Revisión Sistemática de Literatura muestran el grado de precisión del uso de algoritmos neuronales al evaluar las imágenes médicas. Por tanto, se concluye que las CNN han generado resultados muy útiles para emitir un diagnóstico oportuno al momento de validar casos positivos de COVID-19, pero se evidencia que en la mayoría de trabajos revisados, se ha aplicado un protocolo de evaluación que sobreestima los resultados.

Palabras clave: Aprendizaje profundo; inteligencia artificial; redes neuronales convolucionales; aprendizaje automático.

Abstract

The crisis generated on the planet by COVID-19 (SARS-CoV-2) caused a devastating effect worldwide, and for this reason, an effective detection of the possible contagion of infected patients was needed. In this sense, the present work gathers information from diagnostic tools that use Deep Learning (DL) in medical images to detect COVID-19. It is a descriptive observational study. In addition, the purpose of this study is to analyze and compare how DL applied to radiographic images optimizes resources and management of results in an objective and timely manner, showing a favorable cooperation between the health, institutional and technological sectors. In such a way that Convolutional Neural Networks (CNN) in their different algorithms are the chosen architecture in the biomedical area for the diagnosis of diseases applied to the analysis of radiographic images, which purpose is to help the medical service to lighten the attention of patients with an early detection of symptoms and risk factors of the COVID-19 virus, due to the number of symptomatic and asymptomatic patients. The results of this Systematic Literature Review show the degree of accuracy of the use of neural algorithms when evaluating medical images. Therefore, it is concluded that CNNs have generated very useful results to issue a timely diagnosis when validating positive cases of COVID-19, but it is evident that in most of the reviewed works, an evaluation protocol that overestimates the results has been applied.

Keywords: Deep learning; artificial intelligence; convolutional neural network; machine learning.

1. Introducción

El virus COVID-19 es una enfermedad infecciosa que fue declarada por la Organización Mundial de la Salud (OMS) como emergencia sanitaria y que ocasionó el fallecimiento de muchas personas, contabilizados en su mayoría como neumonías atípicas (OMS, 2021), cuyos primeros casos fueron reportados en Wuhan China a finales del 2019, propagándose de manera vertiginosa por todo el planeta (Márquez, 2020). Este escenario no solo afectó el sector sanitario, también ocasionó crisis económica (Aguilar, 2021, p. 5).

Para apoyar esta emergencia sanitaria mundial, que ha causado muchas muertes en más de 216 países y principalmente entre personas en condiciones de enfermedades preexistentes como: cardiovasculares, diabetes, hipertensión, asma y obesidad (World Health Organization, 2020), muchos países no tenían pruebas de PCR y RT-PCR bien estandarizadas, debido a los inconvenientes del alto costo, la falta de kits y los diagnósticos lentos (Belman, 2022), proceso que consume un tiempo mínimo de 6 horas para confirmar la infección (López et al., 2020), así como problemas de recolección de muestras para diagnosticar pacientes con COVID-19, situación que generó un 30 % a 40 % de falsos positivos y falsos negativos (Peco, 2020), Ante esta situación, se propuso el análisis de imágenes médicas en combinación con la tecnología, como una alternativa más precisa para diagnósticos más acertados (Tillaguango, 2021).

Ante el panorama expuesto, fue crucial la toma de decisiones del sector sanitario en forma inmediata que garantice un uso eficiente de recursos de salud que controle y reduzca el número de contagiados. Por ello, la Revisión Sistemática de Literatura (RSL) se efectuó mediante la metodología de Barbara Kinchenhan, que permitió recabar un gran número de artículos con temas relacionados al diagnóstico de COVID-19 que utilizó técnicas y métodos alternativos que permitieran corroborar la aplicación de Inteligencia Artificial (IA) a estos procedimientos, siendo el modelo de redes neuronales convolucionales (CNN) aquel que utiliza el reconocimiento de patrones en imágenes pulmonares que alcanzaron su mayor grado de precisión (Tillaguango, 2021; López et al., 2020).

El objetivo de este trabajo es presentar un análisis bibliométrico de tipo cualitativo sobre la evolución y procedencia de la presente investigación, así mismo se pretende analizar el nivel de precisión y los impactos de aquellas investigaciones que fueron objeto del presente estudio, cuya finalidad es producir un estado de la cuestión que demuestre que la tecnología apoya al sector sanitario al momento de realizar un diagnóstico oportuno al utilizar las redes neuronales convolucionales que analizan las imágenes radiográficas.

El uso de los rayos X consituye una herramienta de diagnóstico para posibles pacientes COVID-19, además de rápidas y económicas, lo que permite a los médicos analizar las imágenes médicas en menor tiempo para confirmar o descartar la presencia del virus (Apostolopoulos & Mpsiana, 2020; López et al., 2020), así como el triaje, identificación y medición de la gravedad en caso de confirmar dicha infección (Firmeza et al., 2021). Así, surgen preguntas como ¿Quién es el responsable del diagnóstico al utilizar redes neuronales convolucionales en el análisis de imágenes radiográficas?, ¿Las redes neuronales convolucionales (CNN) apoyaron al sector médico en los diagnósticos de COVID-19 utilizando imágenes radiográficas?

Por lo que hay que clasificar a la enfermedad como de bajo o alto riesgo o que tenga un buen o mal pronóstico y dicha decisión tomada, por lo general, por un médico sea trasladada al algoritmo neuronal, sea validada y clasificada para que con precisión pueda apoyar al sector

sanitario (Menéndez, 2019).

1.1. Fundamentos de las redes neuronales convolucionales aplicado al diagnóstico de COVID-19.

Uno de los avances significativos de la tecnología es la Inteligencia Artificial (IA), término acuñado en 1956, el cual consistía en que las máquinas resuelvan problemas que solo lo realizaban los humanos (Uría, 2019). De la IA se desprenden el Machine Learning (ML) primero y luego el DL, del cual el ML se trata de modelos de aprendizaje automático que son capaces de aprender por sí mismos, reconocen patrones y pueden predecir comportamientos a partir de un conjunto de datos alimentados al algoritmo (Sarmiento, 2020; Artola, 2019; Abellán, et al., 2021).

El DL es una técnica del Machine Learning cuya arquitectura consiste de una red de neuronas artificiales con múltiples capas ocultas que por medio de sensores se activan las capas subsiguientes con la finalidad de que el algoritmo realice su tarea de aprendizaje automático (Trusculescu et al., 2020), sin supervisión ni etiquetado de imágenes y muy potente para casos de reconocimiento imágenes como patrones faciales (Artola, 2019; Sarmiento, 2020; Armada, 2021).

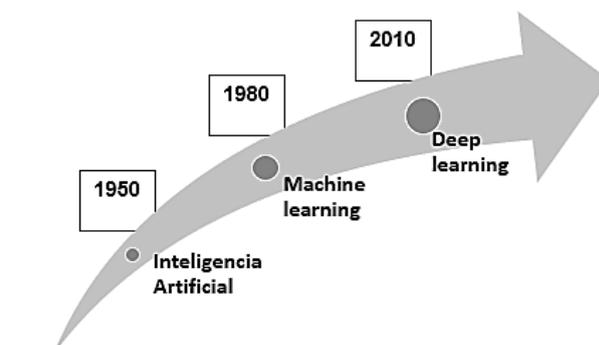
Los algoritmos de DL evalúan continuamente los datos e infieren conclusiones debido al continuo aprendizaje automático y esto se logra porque utiliza los modelos computacionales llamados redes neuronales artificiales (ANN), las cuales se clasifican en: Deep Neural Network (DNN), Redes Neuronales Convolucionales (CNN) y las redes neuronales recurrentes (RNN) (Abellán, et al., 2021; Armada, 2021).

El presente estudio se enfoca en las CNN que son un tipo de algoritmos ANN que han tenido mucho éxito en el análisis y procesamiento de visión artificial, como clasificar, reconocer patrones, comparar y/o segmentar imágenes (Abellán, et al., 2021; Belman, 2022; Mera & Ochoa, 2021; Sarmiento, 2020; Armada, 2021).

Los avances tecnológicos cooperan con el sector sanitario, como es el caso de la Inteligencia Artificial (IA), que la conforman una serie de algoritmos lógicos entrenados, basados en redes neuronales biológicas humanas, los cuales permiten a las máquinas tomar decisiones para mejorar resultados (Ávila et al., 2021).

Figura 1

Línea temporal de los campos de inteligencia artificial



En la figura 1, se puede apreciar la evolución de la Inteligencia Artificial (IA), pasando por el Machine Learning hasta llegar al Deep Learning.

Los autores Medhi et al. (2020) afirman que las redes neuronales son modelos de aprendizaje profundo que se utilizan para anticipar, categorizar o controlar problemas en diferentes ámbitos como la medicina, la ingeniería, etc., y se requiere su aplicación cuando no se puede determinar la naturaleza de la relación entre los valores de entrada y salida, porque las redes neuronales aprenden de los valores de entrada y salida (Mera & Ochoa, 2021) que son conocidas como entrenamiento, de esta forma, en las redes neuronales existen tres tipos de entrenamiento: aprendizaje por refuerzo, supervisado y no supervisado (Espino T, 2017).

El proceso de entrenamiento es garantizado con la estrategia Transfer Learning, debido a que el estado del arte de las CNN requieren de un gran conjunto de datos para desarrollar precisión y obtener un resultado efectivo, producto del análisis de las imágenes médicas (Apostolopoulos & Mpsiana, 2020; Nour et al., 2020).

1.2 Principios de Ética y de Sesgos en los Algoritmos de Deep -Learning

Abellán et al. (2021) afirma que la tecnología y la ética deben reforzarse, para que al aplicar IA no existan sesgos que afecten la calidad de los resultados (Daley, 2020; Ávila et al., 2020). En ese sentido instituciones como Microsoft, IBM FAO, etc. exhortan que el enfoque tecnológico sea encaminado al bien de la humanidad, donde la integridad ética de la raza humana permanezca intacta, minimizando aquellos desafíos que atenten contra la sociedad en general (Abellán et al., 2021).

Los sesgos son susceptibles de generar Falsos positivos, Falsos negativos, Verdaderos positivos y Verdaderos negativos, debido a cómo se clasificaron las imágenes, calidad y etiquetado, además de condiciones de sintomatología de pacientes hospitalizados por lo que habría que considerar una correcta combinación, así como tener una considerable cantidad de las imágenes para que el algoritmo aprenda y discrimine los casos de COVID-19, neumonía y pacientes sanos (López et al., 2020).

1.3 Algoritmos Neuronales convolucionales

Las redes neuronales convolucionales son un tipo de arquitectura de red neuronal artificial de aprendizaje profundo, que aprende por retroalimentación de los datos, permitiendo a estas nuevas arquitecturas de redes la flexibilidad en el reconocimiento de patrones como son las imágenes médicas CT y Rx , la cual han demostrado tener una curva de aprendizaje mayor al momento de tener un conjunto enorme de datos para reconocimiento de imágenes y, de esta manera, generar resultados más precisos y en corto tiempo (Tillaguango, 2021), además, son muy efectivos para reconocimiento de visión artificial, como clasificación y segmentación de imágenes, entre otras aplicaciones, ya que las analiza automáticamente y extrae características necesarias (Arias et al., 2019).

Las redes neuronales profundas pueden identificar y reconocer patrones casi imperceptibles para el cerebro humano, incluso es una potencial herramienta que sirve de apoyo para generar un diagnóstico de posibles afecciones que se evidencien en dichas imágenes médicas (Martínez et al., 2019; Tillaguango, 2021; Medinaceli & Díaz, 2021).

Los algoritmos evolucionan de acuerdo con la cantidad de datos con que se les alimente, no se basan en reglas, sino que mejoran con el aprendizaje automático por la retroalimentación que recibe, logrando resultados específicos mediante el procesamiento de grandes cantidades de datos (López et al., 2021).

Las CNN son una notable técnica de aprendizaje automático, clasificándolo como un algoritmo idóneo para el análisis de radiografías automatizadas específicamente para los casos de detección de afecciones respiratorias en diversas técnicas de análisis de imágenes para la detección del COVID-19 (Esparza, 2020; El Asnaoui et al., 2020), así mismo, las CNN son técnicas de DL muy conocidas y utilizadas no solo en el ámbito de salud como clasificador de imágenes ofreciendo un amplio espectro de investigación (Islam et al., 2020; Apostolopoulos & Mpsiana, 2020; López et al., 2020).

2. Métodos

El alcance de la revisión sistemática realizada, tiene la finalidad de analizar las redes neuronales convolucionales en imágenes radiográficas para el diagnóstico del COVID-19. Por ello, se revisaron artículos publicados desde el año 2019 en bases de datos como PubMed, Scielo, Scopus, Dialnet, Latindex, Redalyc y ResearchGate, así como buscadores; Google Scholar y RediB tal como se observa en la tabla 1. Para la búsqueda de los artículos, se utilizaron términos como: *Machine learning in Medicine*, *Deep Learning in Medicine*, *Artificial Intelligence in Medicine*, *Redes neuronales en COVID-19* y *Artificial Intelligence to Analyze Chest Radiographs for Signs of COVID-19*. La RSL se apoya en la metodología de Bárbara Kitchenham y se la eligió por ser flexible para el investigador en la obtención de resultados y su futura publicación.

Tabla 1

Estudios encontrados y seleccionados por cada una de las bibliotecas Virtuales

Fuente	Encontrados	Seleccionados
PubMed	151	11
Scielo	21	2
Dialnet	1	1
Redalyc	6	2
ResearchGate	20	4
Google Scholar	10	5
IEEE Journal	1	1
Redib	1	1
Total	231	27

2.1 Criterios de inclusión y exclusión (criterios IC/EC)

Como criterio de inclusión y con el fin de evaluar la calidad de la evidencia, se tomaron en consideración artículos y revisiones escritas en español o inglés (Tabla 1), donde se incluyó el título de la publicación, Institución y fuente, cuyo fin en común involucraba a instituciones, investigadores, así como personal sanitario del ámbito de radiología, y para dar respuesta a las *preguntas* de investigación se aplicó la técnica de análisis de contenido. Como menciona Franco (2020) que cita a Dauster y Carter (1960, p. 2), el análisis de contenido “se basa en la lectura (textual o visual) como instrumento de recolección de información y lectura, que a diferencia de la lectura común debe realizarse siguiendo el método científico, es decir, debe ser sistemática, objetiva, replicable, y válida”.

Se excluyeron artículos duplicados, así como comentarios editoriales y de autores, comunicados, noticias, opiniones y recomendaciones clínicas.

Luego se filtraron los artículos con el objetivo de utilizar los de mayor relevancia al contenido. Finalmente, se revisaron los artículos completos cuyo criterio de selección corresponden a trabajos de radiología y redes neuronales convolucionales relacionados a la COVID-19.

Desde una perspectiva general, el presente estudio se aborda con un marco teórico que incluye el uso de Redes Neuronales convolucionales para revisión de imágenes médicas utilizadas en el diagnóstico de COVID-19.

2.2 Fuentes y Técnicas para recolección de información

Las fuentes de información son secundarias, ya que son basadas en la producción intelectual de otros autores.

3. Resultados

De los 27 artículos seleccionados, 15 estudios no mostraron toda la información para un análisis de variables como: cantidad de imágenes utilizadas, porcentaje de precisión en el algoritmo y/o tipo específico de imagen médica analizada, motivo por el que se descartaron y solo se analizaron 12 estudios como se aprecia en la Tabla 2.

La COVID-19 ha demandado el uso de herramientas tecnológicas como la Inteligencia Artificial (IA), así como el almacenamiento en la nube con la intención de reducir el tiempo de respuesta para realizar un diagnóstico a personas con posibles contagios. Es decir, la conectividad digital ayudó a guardar el distanciamiento social y cumplir con las medidas de bioseguridad, a su vez que las empresas pudieran optar por el teletrabajo, situación que ha desafiado a la imaginación con soluciones tecnológicas para controlar el avance de los contagios, por medio de ciertos aplicativos como Alipay Health Code, cuya función es asignar un código de colores según el estado de salud y que les permita moverse en transporte público. Así también el uso de sensores de calor para detectar aglomeraciones y síntomas febriles, otras invenciones como el uso de cascos inteligentes que detectan personas con fiebre hasta una distancia de cinco metros, mientras otras alternativas fueron desarrolladas para

predecir posibles brotes de contagio, uso de robots para: desinfección de lugares públicos, atención hospitalaria, envíos de encomiendas, etc. (Caf et al., 2020).

3.1 Criterios de Inclusión

Se consideró los siguientes:

- Artículos publicados a partir de 2019 en adelante
- Artículos en inglés o español
- Artículos relacionados a métodos de IA, ML, DL y CNN para identificar o diagnosticar a pacientes con COVID-19
- Artículos que mencionan el análisis de imágenes médicas Rx, CT.

3.2 Criterios de Exclusión

Se consideró los siguientes:

- Artículos cuyas publicaciones sean menores al 2019
- Artículos que no mencionan, reconocen o diagnostican el COVID-19
- Métodos o técnicas de detección o diagnóstico ambiguos
- Estudios que no especificaban la cantidad de imágenes médicas utilizadas.
- Publicaciones sin fecha

En la tabla 2, se visualiza aquellas publicaciones tanto de autores como instituciones involucradas en la investigación y uso de algoritmos neuronales aplicados al diagnóstico en posibles pacientes con COVID-19 a partir de imágenes radiográficas que utilizaron Deep Learning (DL) que obtuvieron un alto porcentaje de efectividad o precisión, entrenando una cierta cantidad de conjunto de datos (detallado en Tabla 3) y que ha permitido la construcción de modelos computacionales de múltiples capas, dicho esquema sirvió de diagnóstico acorde a los parámetros programados (Franco, 2020).

En la tabla 3, se desglosa el estudio de diversos investigadores que analizaron diferentes imágenes médicas versus el algoritmo neuronal que resultó con mayor precisión para la detección de COVID-19.

Los investigadores utilizaron algunas metodologías como el de Civit-M et al., con el algoritmo VGG-16 basado en DL para la detección del COVID-19, logrando una precisión del 100 % al utilizar un total de 5 887 imágenes obtenidas de un sitio de acceso público. Wang & Wong con el algoritmo COVID-Net, presentan un modelo basado en Deep learning para la detección de COVID -19. COVID-Net alcanzó una precisión del 92,4 % utilizando un total de 16 756 imágenes de radiografías obtenidas de diferentes datos de acceso abierto. Van Ginneken presenta tres estudios con diferentes algoritmos, DeepCovid-XR que fue entrenado con casi 15 000 imágenes de las cuales 4 000 fueron positivas a COVID-19 mostrando una precisión del 88 %; el segundo estudio con el algoritmo CAD4COVID-X-ray se alimentó la red neuronal con 454 imágenes de las cuales 223 eran casos positivos a Covid-19, además este algoritmo fue preentrenado con 416 imágenes de otro hospital mostrando una precisión del 81 %; y finalmente, el tercer caso es con el algoritmo CV19-Net entrenado con imágenes del Centro de Salud Henry Ford con un total de 5 000 imágenes, de las cuales la mitad de ellas eran positivas a COVID-19 con una precisión del 94 %. Panwar et al., logró una precisión del 97 % con el modelo CovNet de un total de 337 imágenes, las cuales 193 eran positivas a COVID-19.

Tabla 2

Artículos de Investigación Analizados

ID	Título	Institución	Fuente
P1	Deep Learning System for COVID-19 Diagnosis Aid Using X-ray Pulmonary images	Universidad de Sevilla	Civit-M et al. (2020)
P2	Automatic Detection of COVID-19 Infection Using Chest X-Ray Images Through Transfer Learning	Universidad de Fortaleza	Firmeza et al. (2021)
P3	ai-corona: Radiologist-Assistant Deep Learning Framework for COVID-19 Diagnosis in Chest CT Scans	IPM, NRITLD Teherán (Irán)	Yousefzadeh et al. (2020)
P4	The Potential of Artificial Intelligence to Analyze Chest Radiographs for Signs of COVID-19 Pneumonia	Northwestern Memorial Health Care System	Van Ginneken (2020)
P5	Uso de imágenes de rayos X y aprendizaje profundo para detección automatizada de la enfermedad por coronavirus	Mohammed VI Polytechnic University (Marruecos), Moulay Ismail University (Marruecos)	El Asnaoui & Chawki (2020)
P6	Aplicación de aprendizaje profundo para la detección rápida de COVID-19 en rayos X usando nCOVnet	Jaypee University of Information Technology (India), Instituto Tecnológico de Monterrey (México)	Panwar et al. (2020)
P7	Análisis de algoritmos de aprendizaje profundo en la base de datos de radiografías COVID-19	Krishna Institute of Engineering And Technology (India)	Jaiswal & Singh, (2020)
P8	Diagnóstico de la neumonía COVID-19 a partir de imágenes de rayos X y TC mediante algoritmos de aprendizaje profundo y aprendizaje por transferencia	Koya University (Iraq), University of Wolverhampton (Reino Unido), King Saud University (Arabia Saudita)	Maghdid (2020)
P9	COVID-Net: un sistema neuronal convolucional profundo personalizado Diseño de red para la detección de casos COVID-19 a partir de imágenes de rayos X de tórax	University of Waterloo (Canadá)	Wang & Wong, (2020)
P10	Detección automatizada de casos de COVID-19 utilizando redes neuronales profundas con imágenes de rayos x	Firat University (Turquía), University of Bristol (UK), Munzur University (Turquía), Ngee Ann Polytechnic, (Singapur), Asia University (Taiwan), Kumamoto University (Japón)	Barstugan et al. (2020)
P11	A deep learning approach to characterize 2019 coronavirus disease (COVID-19) pneumonia in chest CT images	Nanjing University	Qianqian et al. (2020)
P12	Artificial intelligence distinguishes COVID-19 from community acquired pneumonia on chest CT	Wuhan Hospital et al.	Li et al. (2020)

Nota. Adaptado de Franco (2020)

Firmeza et al. tuvieron una precisión del 98 %, de un total de 676 imágenes con solo 194 casos positivos para COVID-19. Jaiswal & Singh indicaron que el resultado de la precisión de su algoritmo fue del 99 %, donde se hicieron pruebas en algunos modelos como VGG, DenseNet, ResNet, Inception, NasNet, and MobileNet. Maghdid (2022), con el modelo AlexNet mostró una precisión del 98 %. Barstugan et al., con un total de 618 imágenes, de las cuales 219 eran COVID19 + utilizadas en algunos modelos neuronales, obtuvo un 99 % de precisión en el algoritmo GLSZM. Qianqian et al., con una muestra de 14 435 imágenes solo 96 eran positivas COVID-19, mostró una precisión de 95 % en el modelo MVP-Net. Li et al., con una muestra de 4 356 imágenes de seis centros médicos distintos, dio una precisión de 90 % con el algoritmo CovNet. Yousefzadeh et al., contaba con una muestra de 7 184 imágenes médicas, donde 5 693 eran positivas a COVID-19 cuyo algoritmo EfficientNetB3 mostró un 95 % de precisión.

Tabla 3

Algoritmos de Deep Learning con valores de precisión

Estudio de autores	Tipo de imágenes	Número de casos	Algoritmo usado	Precisión (%)
Civit-M et al.	Chest X-ray	132 COVID-19(+), 132 Pneumonia, 132 Healthy	VGG-16	100
Wang & Wong	Chest X-ray	53 COVID-19(+), 5526 COVID-19 (-), 8066 Healthy	CovidNet	92,4
Van Ginneken	Chest X-Ray	223 COVID-19+ 4000 COVID19+ 5000 trainee	CAD4COVID-x-ray DeepCOVID-XR CV19-Net	81 88 94
Panwar et al	CT/Chest-Ray	337 total images, 192 COVID-19(+), 142 Healthy	COVnet	97
Firmeza et al.	X-Ray	194 COVID-19 + 194 Healthy	MobileNet +SVM linear	98
Jaiswal & Singh	X-Ray	Various sources	VGG, DenseNet, ResNet, Inception, NasNet, and MobileNet	99
Maghdid	CT/X-Ray	120 Xray (60 COVID;60 Healthy) 339 CT (192 COVID19)	AlexNet	98
Barstugan et al.	Chest X-Ray	219 COVID19 + 224 influenza 175 healthy	GLCM, LDP, GLRLM, GLSZM, DWT algorithms	99
Qianqian et al.	CT	14,435 96 COVID19+	MVP-Net	95
Li et al.	CT	4356	CovNet	90
Yousefzadeh	CxR	7184 images	DenseNet, ResNet, Xception, and Efficient- NetB0 through EfficientNetB3, ImageNet	95
El Asnaoui & Chawki.	X-Ray, CT images	1724 COVID-19(+), 2780 Bacterial pneumo, 1583 Healthy	Inception_Resnet_V2	92

Nota. Adaptado de Pereira et al. (2020); Ozturk et al. (2020).

El Asnaoui et al. tuvieron una precisión del 92 % al utilizar el modelo Inception_Resnet_V2 con la característica de tener disponibles 1 724 imágenes de pronóstico COVID-19, 2 780 imágenes con diagnóstico de neumonía Bacterial y 1 583 imágenes de pacientes sanos. Lo común de estos estudios es que los realizaron con pocos datos para desarrollar el modelo.

Los algoritmos descritos en la tabla 3 muestran diferentes porcentajes de precisiones, pero son métodos que han evaluado pocas imágenes médicas y para que sea realmente representativa y con credibilidad su resultado, el algoritmo neuronal debe tener cientos de miles de imágenes para aprender, además de clasificar correctamente las imágenes para que el algoritmo realice una evaluación eficiente y por ende resulte en un diagnóstico concluyente. Pero cabe recalcar que en todos los estudios mencionados en la tabla 3, sus autores concluyen que incide mucho la calidad de la imagen, la cantidad de ellas (Maghdid, 2020, p.7; Jaiswal & Singh, 2020; Yousefzadeh, 2021; Firmeza et al., 2021), el etiquetado correcto para evitar sesgos y diagnósticos erróneos (López et al., 2020); y como requisito principal se necesita la experiencia del radiólogo, así como el diagnóstico oportuno para emitir su criterio profesional (Esparza, 2020; López et al., 2020; Firmeza et al., 2021; Ozturk et al., 2021).

La calidad de la imagen varía así como su precio, la más económica y de rápida entrega son los Rayos X de pecho (CRX). En cuestión de minutos, se puede hacer el diagnóstico; la tomografía computarizada (TC) es un poco más costosa y demora hasta dos días para su entrega al paciente; y la resonancia magnética (RM) es la más costosa de las tres imágenes médicas; así lo afirman algunos autores (López et al., 2020; Apostolopoulos & Mpsiana, 2020). Por otro lado, los radiólogos no están convencidos de que la inteligencia artificial (algoritmos neuronales) realicen evaluaciones de dichas imágenes médicas con absoluta precisión, porque dichos algoritmos necesitan alimentarse o entrenarse con imágenes para que puedan aprender y emitan un diagnóstico sin errores (Cohen, Hashir & Brooks, 2020; Ozturk et al., 2021; Pereira et al., 2020).

Sin embargo, el DL es una gran ayuda para la detección de múltiples enfermedades debido a su pronta difusión de un resultado, ya que pueden existir muchas anomalías en los hallazgos radiológicos, cuya interpretación práctica en la vida real difiere entre el uso de IA y el diagnóstico de un médico (Corbacho et al., 2020), esto se debe por la calidad de la imagen versus precio sea Rayos x de pecho (CRX), Tomografía computarizada (TC) o imagen de resonancia magnética (MRI) que alimente al algoritmo (transfer learning) y que, por ende, se requiere de la presencia del radiólogo experimentado para que realice su diagnóstico profesional en casos de neumonías virales, bacterianas y/u otras patologías (López et al., 2020; Apostolopoulos & Mpsiana, 2020).

La sensibilidad del algoritmo ha demostrado una ligera ventaja superior a la de los radiólogos residentes, al momento de realizar la detección de anomalías a partir de imágenes de TC de pacientes confirmados de COVID-19 (Qianqian et al., 2020; El Asnaoui & Chawki, 2020).

La arquitectura de los algoritmos informáticos basados en redes neuronales convolucionales que han sido entrenados con una gran cantidad de imágenes de radiografías y tomografías computarizadas, intentan realizar un diagnóstico más específico y anticipado en pacientes que presenten afecciones pulmonares a través de un procesamiento automático de imágenes que han sido previamente analizadas por personal de salud especializado (González

et al., 2021), mejorando en forma considerable la eficiencia del trabajo del radiólogo (Corbacho D., 2020; Pereira et al., 2020).

Basado en lo anterior, facilita la posibilidad del manejo de aforos y ubicaciones de la población, para realizar un mejor control de posibles contagios, que con el apoyo de la tecnología, como es el caso de 85 startups aliadas con la fundación Prosegur y su plan piloto en Valencia - España con su lema "Reto Aulas Covid Free", mediante el uso de localizadores en la vestimenta, vigilan la distancia de grupos menores a 1,5 metros, iniciativa que podría replicarse en otros sectores (Pérez, 2020).

4. Discusión

De los resultados obtenidos en la RSL sobre la precisión de los Algoritmos informáticos basados en redes neuronales convolucionales (CNN) para el diagnóstico de COVID-19, se evidencia una fiabilidad de más del 90 % al analizar las imágenes radiográficas, pero todos los estudios mencionados en la tabla 2 no cumplen con la cantidad mínima para alimentar el algoritmo (entrenamiento) para minimizar o eliminar los sesgos y que de un resultado válido, preciso y concluyente, como lo mencionan algunos autores (Maghdid, 2020, p.7; Jaiswal & Singh, 2020; Yousefzadeh, 2021; Firmeza et al., 2021).

En consecuencia, las imágenes médicas más viables para la detección de la COVID-19 son la TC y las radiografías pulmonares utilizando CNN, siendo más costosa la TC debido a la complejidad de los equipos, pero lo primordial al momento de seleccionar las imágenes de TC o de Rx pulmonares es el correcto etiquetado y validación por parte radiólogos expertos para que se realice un diagnóstico apropiado y preciso (Franco, 2020; Corbacho D., 2020).

En la presente RSL se evidenció que para brindar un mejor diagnóstico se requiere un entrenamiento más profundo de los algoritmos de redes neuronales (Corbacho et al., 2020) alimentándolos con las imágenes radiográficas (Islam et al., 2020; Apostolopoulos & Mpsiana, 2020; El Asnaoui & Chawki, 2020) para precisar sus decisiones diagnósticas (atributos clínicos), así también que se optimice la calidad de las imágenes, protocolos etc. Esto significa que al menos unos cientos, miles o millones de imágenes se necesitarían para que aprenda o entrene previamente el algoritmo neuronal (Trusculescu, et al., 2020). A mayor entrenamiento de las redes neuronales mostrarán mejores resultados con una opción más viable del modelo de reconocimiento de patrones que garantice mejor precisión (Tillaguango, 2021).

Como limitación, vale mencionar la poca cantidad de imágenes que se tuvo en los diversos estudios mencionados en la presente RSL, ya que las redes neuronales convolucionales aprenden con la experiencia. Además, se requirió el apoyo del personal sanitario experimentado para que realicen el correcto etiquetado en las imágenes conforme a su habilidad para realizar dicha actividad (Ilyas et al., 2020), así como segmentar o señalar las lesiones relacionadas con la COVID-19 en dichas imágenes radiográficas (Muñoz, et al., 2020), donde el personal sanitario debía tener experticia en análisis de biopsias entre otros, cuyas características son difíciles de encontrar (López et al., 2021).

5. Conclusiones

De esta manera, queda en evidencia que los algoritmos con estructura neuronal son capaces de aprender y organizar sus redes neuronales, mostrando un continuo aprendizaje, los cuales ayudarían a diagnosticar en menor tiempo y a clasificar pacientes en diferentes etapas de la enfermedad (Corbacho et al., 2020). Así mismo el autor Tillaguango (2021) afirma que el uso de las CNN son una opción viable para el diagnóstico automático y eficiente de pacientes con COVID-19 aplicando estrategias de Transfer Learning a los algoritmos CNN (Islam et al., 2020).

Algunos expertos en análisis de imágenes radiográficas afirman que aún se necesita de la presencia del especialista médico para realizar un diagnóstico oportuno, aunque la experiencia ha demostrado que dichos algoritmos neuronales aprenden con base a la alimentación de los datos, factor importante a considerar al momento de eliminar los sesgos y así obtener un resultado idóneo e imparcial para un diagnóstico eficaz, oportuno y objetivo (Serofca, 2021; Pereira et al., 2020).

Los resultados alcanzados en este trabajo se basaron en el empleo de las técnicas de DL específicamente (CNN) (García et al., 2020; Tillaguango, 2021; Ozturk, et al., 2020; Pereira et al., 2020; Wang & Wong, 2020), los cuales permiten ratificar conocimiento existente sobre esta nueva enfermedad (COVID-19). Así también que los especialistas sanitarios y de tecnología puedan colaborar de forma conjunta para beneficio de la población afectada por el virus y que permita diagnosticar de manera ágil y precisa utilizando una interfaz de CNN, cuyo promedio de procesamiento para emitir un resultado de una imagen de CT es 4,51 segundos dependiendo de las características del equipo de cómputo (Li et al., 2020).

Se propone para futuras investigaciones obtener una gran cantidad de imágenes médicas (CRX, TC, MR) para alimentar o entrenar a aquellos algoritmos neuronales con la finalidad de que apoyen al sector sanitario a emitir un diagnóstico preciso, para brindar asistencia y aligerar la carga de pacientes (Ozturk, et al., 2020; Nour et al., 2020; El Asnaoui & Chawki, 2020).

Finalmente, se recomienda que en futuros estudios se consideren también aquellas investigaciones que utilicen técnicas diferentes a la imagenología para la detección de afecciones respiratorias. Por otro lado, se sugiere no limitarse en la búsqueda de artículos en un solo idioma y que las fuentes internacionales sean una alternativa importante a la hora de buscar otras publicaciones (Esparza, 2020).

6. Referencias Bibliográficas

Abellán, F., Barón, F., Del Barrio, J., Fernández, O., García, X., García, J.,... Urriés, A. (2021). *Inteligencia Artificial en el campo de la salud. Un nuevo paradigma: Aspectos clínicos, éticos y legales.* (F. M. Salud, Editor) ISBN: 978-84-18568-02-2. https://www.fundacionmercksalud.com/wp-content/uploads/2021/02/digital_monografia-26_inteligencia-artificial_final-1.pdf

- Apostolopoulos, L., & Mpsiana, T. (2020). *Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks*. De Phys Eng Sci Med 43, 635–640. <https://doi.org/10.1007/s13246-020-00865-4>
- Arias, V., Salazar, J.,..., & Bermúdez, V. (2019). Una introducción a las aplicaciones de la inteligencia artificial en Medicina: Aspectos históricos. *Revista Latinoamericana de Hipertensión*. Vol. 14 Núm. 5. <https://www.redalyc.org/journal/1702/170262877013/html/>
- Armada, B. (2021). *Utilización de Técnicas de Machine*. <https://repositorio.comillas.edu/xmlui/bitstream/handle/11531/46947/TFG%20-%20Armada%20Carrion%2C%20Belen%202.pdf?sequence=2>
- Artola, A. (2019). *Clasificación de imágenes usando redes neuronales convolucionales en Python*. <https://idus.us.es/bitstream/handle/11441/89506/TFG-2402-ARTOLA.pdf?sequence=1&isAllowed=y>
- Ávila, J., Mayer, M., & Quesada, V. (2021, enero). La inteligencia artificial y sus aplicaciones en medicina II: importancia actual y aplicaciones prácticas. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7752970/>
- Barstugan, M., Ozkaya, U., & Ozturk, S. (2020). *Coronavirus (COVID 19). Classification using CT images by Machine learning methods*. <https://arxiv.org/abs/2003.09424>
- Belman, C. (2022). *Detección de COVID-19 y otros casos de neumonía utilizando redes neuronales convolucionales e imágenes de rayos-X*. Vol. 42 N- 1. <https://doi.org/10.15446/ing.investig.v42n1.90289>
- Caf, Cepal, Digital Policy and Law, Telecom Advisory Services Llc. (2020). *Las oportunidades de la digitalización en América Latina frente al Covid-19*. https://www.cepal.org/sites/default/files/publication/files/45360/OportDigitalizaCovid-19_es.pdf
- Civit-M, J., Luna, F., Domínguez, M., & Civit, A. (2020, Julio 5). *Deep Learning System for COVID-19 Diagnosis Aid Using X-ray Pulmonary images*. <https://doi.org/10.3390/app10134640>
- Cohen, J. P., Hashir, M., & Brooks, R. &. (2020). *On the limits of cross-domain generalization in automated X-ray prediction*. arXiv:2002.02497 [cs, eess, q-bio, stat]. <http://arxiv.org/abs/2002.02497>
- Corbacho, D. (2020, enero). *Povisa lidera una investigación para mejorar el diagnóstico del cáncer de pulmón con tecnología Machine Learning*. <https://riberasalud.com/povisa/povisa-lidera-una-investigacion-para-mejorar-el-diagnostico-del-cancer-de-pulmon-con-tecnologia-machine-learning/>
- Corbacho, D., Ruano, A., & Fernández, A. (2020, octubre 22). *Inteligencia artificial en radiología torácica. ¿Un reto en tiempos de la COVID-19?*. <https://www.archbronconeumol.org/es-inteligencia-artificial-radiologia-toracica-un-articulo-S0300289620303884>
- Daley, B. (2020, agosto 10). *Discriminación racial en la inteligencia artificial*. <https://theconversation.com/discriminacion-racial-en-la-inteligencia-artificial-142334>

- El Asnaoui, K., & Chawki, Y. (2020). *Using X-ray images and deep learning for automated detection of coronavirus disease*. *Journal of Biomolecular Structure and Dynamics*, 0(0), 1–12. <https://doi.org/10.1080/07391102.2020.1767212>
- Esparza, J. (2020). *Redes Neuronales Convolucionales en la detección de afecciones respiratorias de los sistemas locales de salud: Una revisión sistemática entre los años 2010 y 2020*. [https://repositorio.upn.edu.pe/bitstream/handle/11537/25838/Jose Esparza REVISI% c3%93N-Sistem% c3%81TICA%20total.pdf?sequence=1&isAllowed=y](https://repositorio.upn.edu.pe/bitstream/handle/11537/25838/Jose_Esparza_REVISI%c3%93N-Sistem%c3%81TICA%20total.pdf?sequence=1&isAllowed=y)
- Espino T, C. (2017, enero 16). *Análisis predictivo: técnicas y modelos utilizados y aplicaciones del mismo - herramientas Open Source que permiten su uso*. <http://openaccess.uoc.edu/webapps/o2/bitstream/10609/59565/6/caresptimTFG0117mem%C3%B2ria.pdf>
- Firmeza, E., Maia, G., Souza, J., Vieira, A., Bessa, A., & C. de Albuquerque, V. (2021, Enero). *Automatic Detection of COVID-19 Infection Using Chest X-Ray Images Through Transfer Learning*. <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9205687>
- Franco, J. (2020, 11 06). *Aplicación de la inteligencia artificial (IA) en imagen médica durante la crisis del Covid-19: Un estudio de caso de Deep Learning como invención del “Método de Invención”*. <https://riunet.upv.es/handle/10251/154335>
- García, M., Rodríguez, Y., Ramón, A., Bello, B., Filiberto, Y., Rosete, A., ... Bello, R. (2020). *Adquisición de conocimiento sobre la letalidad de la COVID-19 mediante técnicas de inteligencia artificial*. <http://revistaccuba.sld.cu/index.php/revacc/article/view/891/912>
- González, H., Calleja, A., Gómez, G., Rodríguez, A., & López, L. (2021, Abril 6). *Los conceptos de Machine Learning y Deep Learning en la industria*. <https://www.interempresas.net/MetalMecanica/Articulos/347471-Los-conceptos-de-Machine-Learning-y-Deep-Learning-en-la-industria.html>
- Ilyas, M., Rehman, H., & Nait, A. (2020). *Detection of Covid-19 From Chest X-ray Images*. <https://arxiv.org/pdf/2004.05436.pdf>
- Islam, Z., Islam, M., & Asraf, A. (2020). *A combined deep CNN-LSTM network for the detection of novel coronavirus (COVID-19) using X-ray images*. Vol. 20. <https://doi.org/10.1016/j.imu.2020.100412>
- Jaiswal, A., & Singh, A. (2020). *Analysis of Deep Learning algorithms on COVID19 Radiography Database*. *International Journal of Advanced Science and Technology*. <https://doi.org/10.13140/RG.2.2.27462.91203>
- Li, L., Qin, L., ..., & Xian, J. (2020). *Artificial Intelligence Distinguishes COVID-19 from Community Acquired Pneumonia on Chest CT*. https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7233473/#_ffn_sectitle
- López, D., Bosco, R., Guerrero, C., Zambrano, R., & Saucedo, T. (2021). *Comparación de arquitecturas de redes neuronales convolucionales para el diagnóstico de COVID-19*. ISSN 2007-9737. http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S1405-55462021000300601
- López, J., Portal, J., Orozco, R., & Pérez, M. (2020). *Revisión crítica sobre la identificación de covid-19 a partir de imágenes de rayos x de tórax usando técnicas de inteligencia*

- Artificial. Obtenido de *Revista Cubana de Transformación Digital*. ISSN-e: 2708-3411.vol. 1, núm. 3, 2020. <http://portal.amelica.org/ameli/jatsRepo/389/3891734008/>
- Maghdid, H. S. (2020). *Diagnosing COVID-19 Pneumonia from X-Ray and CT Images using Deep Learning and Transfer Learning Algorithms*. 1–8. <http://arxiv.org/abs/2004.00038>
- Márquez, J. (2020). *Inteligencia artificial y Big Data como soluciones frente a la COVID-19*. ISSN 1886-5887. https://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S1886-58872020000300019
- Martínez Q, J. (2021, Enero). *Identificación no supervisada de zona más relevante en radiografía para la detección de COVID*. <http://repositorio.unab.cl/xmlui/handle/ria/18326>
- Medhi, K., Jamil, & Hussain, I. (2020). *Automatic Detection of COVID-19 Infection from Chest X-ray using Deep Learning*. <https://doi.org/10.1101/2020.05.10.20097063>
- Medinaceli, K., & Díaz, M. (2021). *Impacto y regulación de la Inteligencia Artificial en el ámbito sanitario*. *Revista IUS*. Vol. 15. Núm 48. <https://doi.org/10.35487/rius.v15i48.2021.745>
- Menéndez, P. (2019, Diciembre 19). *Aprendizaje profundo para el diagnóstico de radiografías de tórax en el servicio de urgencias*. <https://doi.org/10.1148/radiol.2019191225>
- Mera, L., & Ochoa, J. (2021). *Redes neuronales convolucionales para la clasificación de componentes independientes de rs-fMRI*. <https://www.redalyc.org/journal/3442/344264813015/344264813015.pdf>
- Muñoz, C., Calvillo, P., Oprisan, A., Alberich, A., Estellés, P., & Martí, L. (2020). *Radiología y COVID-19: un Repaso a una Actuación*. <https://doi.org/10.32440/ar.2020.137.02.rev05>
- Nour, M., Cömert, Z., & Polat, K. (2020). *A Novel Medical Diagnosis model for COVID-19 infection detection based on Deep Features and Bayesian Optimization*. Vol. 97. <https://doi.org/10.1016/j.asoc.2020.106580>.
- Ozturk, T., Talo, M., Azra, E., Baran, U., Yildirim, O., & Acharia, U. (2020). *Automated detection of COVID-19 cases using deep neural networks with X-ray images*. Vol. 121. <https://doi.org/10.1016/j.compbimed.2020.103792>.
- Panwar, H., Gupta, P. K., Siddiqui, M. K., Morales-M, R., & Singh, V. (2020). *Application of deep learning for fast detection of COVID-19 in X-Rays using nCOVnet*. *Chaos, Solitons and Fractals*, 138, 109944. <https://doi.org/10.1016/j.chaos.2020.109944>
- Peco, R. (2020, mayo 5). *La inteligencia artificial detecta la Covid-19 con una radiografía*. <https://www.lavanguardia.com/tecnologia/20200525/481373081626/covid-19-coronavirus-inteligencia-artificial-hospital-del-mar-de-barcelona-tomografias.html>
- Pereira, R. D., Teixeira, L., Silla, C., & Costa, Y. (2020). *COVID-19 identification in chest X-ray images on flat and hierarchical classification scenarios*. <https://doi.org/10.1016/j.cmpb.2020.105532>
- Pérez, H. (2020, noviembre). *Inteligencia artificial: la gran aliada contra la covid-19*. <https://www.compromisoempresarial.com/coronavirus/2020/11/inteligencia-artificial-aliada-contra-covid19/>

- Qianqian, N., Zhi, Y. S., Qi, L., Wen, C., Yi, Y., 3 Li, W., ... Long, J. Z. (2020, Julio). *A deep learning approach to characterize 2019 coronavirus disease (COVID-19) pneumonia in chest CT images*. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7331494/>
- Sarmiento, J. (2020). Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica. *Revista UIS Ingenierías*, vol. 19, núm. 4: <https://www.redalyc.org/journal/5537/553768213002/html/>
- Serofca, (2021, marzo 20). *Inteligencia artificial (IA), aprendizaje automático (ML) y aprendizaje profundo (DL)*. <https://serofca.com/2021/03/20/inteligencia-artificial-ia-aprendizaje-automatico-ml-y-aprendizaje-profundo-dl/>
- Tillaguango, J. (2021). *Revisión sistemática de literatura: análisis de viabilidad para la detección y diagnóstico de Covi-19, aplicando modelos de inteligencia artificial (IA)*. ISSN:1390 5902. <https://revistas.unl.edu.ec/index.php/cedamaz/article/view/1183/855>
- Trusculescu, A., Manolescu, D., Tudorache, E., & Oancea, C. (2020). *Deep learning in interstitial lung disease—how long until daily practice*. <https://link.springer.com/article/10.1007/s00330-020-06986-4>
- Uría, S. (2019). *Visualización en Redes Neuronales Convolucionales*. [https://ri.unlu.edu.ar/xmlui/bitstream/handle/rediunlu/842/Trabajo Final Licenciatura a Uria Santiago 113311.pdf?sequence=1&isAllowed=y](https://ri.unlu.edu.ar/xmlui/bitstream/handle/rediunlu/842/Trabajo%20Final%20Licenciatura%20a%20Uria%20Santiago%20113311.pdf?sequence=1&isAllowed=y)
- Van Ginneken, B. (2020, noviembre 24). *The Potential of Artificial Intelligence to Analyze Chest Radiographs for Signs of COVID-19 Pneumonia*. <https://doi.org/10.1148/radiol.2020204238>
- Wang, L., & Wong, A. (2020). *COVID-Net: A Tailored Deep Convolutional Neural Network Design for Detection of COVID-19 Cases from Chest X-Ray Images*. <https://www.nature.com/articles/s41598-020-76550-z>
- World Health Organization. (2020). *Coronavirus disease (COVID-19) pandemic*. World Health Organization, Geneva. <https://www.who.int/emergencies/diseases/novel-coronavirus-2019>.
- Yousefzadeh, M., Esfahanian, P., Sadegh, s., Gorgin, S., Rahmati, D., Abedini, A., ... Lashgari, R. (2021, Mayo). *ai-corona: Radiologist-assistant deep learning framework for COVID-19 diagnosis in chest CT scans*. <https://doi.org/10.1371/journal.pone.0250952>