

Revisión sistemática de literatura: análisis de viabilidad para la detección y diagnóstico de Covid-19, aplicando modelos de Inteligencia Artificial (IA)

Systematic literature review: feasibility analysis for the detection and diagnosis of Covid-19, applying Artificial Intelligence (AI) models

Jonathan Ricardo Tillaguango Jiménez^{1,*}

¹ Carrera de Ingeniería en Sistemas/Computación, Universidad Nacional de Loja, Loja, Ecuador

* Autor para correspondencia: jonathan.tillaguango@unl.edu.ec

Fecha de recepción del manuscrito: 15/10/2021

Fecha de aceptación del manuscrito: 17/11/2021

Fecha de publicación: 24/12/2021

Resumen— Desde la declaración de la emergencia sanitaria provocada por el Covid-19 en marzo del 2020, hasta la fecha, existen aproximadamente 219 millones de contagiados, de los cuales 4,5 millones han muerto. En nuestro país, se estima que existen 508 mil casos confirmados y aproximadamente 32 mil muertes a causa de esta enfermedad. Pese a disponer de métodos verificados para diagnosticar Covid-19, las pruebas Polymerase Chain Reaction (PCR) o Real Time-PCR (RT-PCR), tienden a generar falsos positivos y negativos entre el 30% y el 40%. Por tal razón, ayudar a los métodos tradicionales a realizar un diagnóstico clínico preciso, usando como datos de entrada radiografías pulmonares, supone un cambio radical en la detección de Covid-19, puesto que, es una alternativa mucho más cómoda para el paciente y lo que es más importante, aumenta el nivel de precisión reduciendo a la vez, las tasas de falsos positivos y negativos. En la presente Revisión Sistemática de Literatura (RSL), la cual se ha basado en la metodología de Bárbara Kitchenham, busca sustentar la creación de un modelo basado en la arquitectura de Redes Neuronales Convolucionales (CNN), capaz de analizar radiografías pulmonares para el diagnóstico de Covid-19. Como resultado, se pudo dar contestación a las tres preguntas de investigación planteadas, mismas que sirvieron para delimitar el presente estudio, para ello se analizó 41 trabajos relacionados (TR), los cuales se enfocaban en diferentes métodos de diagnóstico basados en Inteligencia Artificial (IA), no obstante 16 de estos TR hacían referencia al uso de CNN para el diagnóstico de Covid-19 mediante el análisis de tomografías computarizadas (TC) y radiografías pulmonares (Rayos X), siendo esta última la opción más viable para aplicarlo en nuestro entorno, debido la disponibilidad de datos. Además, el uso de recursos por parte de estos métodos es asequible tanto a nivel local, usando la Unidad de Procesamiento Gráfico (GPU) Nvidia y memoria RAM superior a 8GB como base, o utilizar procesamiento en la nube usando Google Colab.

Palabras clave—Diagnóstico, Covid-19, CNN, VGG16, Radiografías pulmonares, Rayos X.

Abstract— Since the declaration of the health emergency caused by Covid-19 in March 2020, to date, there are approximately 219 million infected people, of which 4.5 million have died. In our country, it is estimated that there are 508 thousand confirmed cases and approximately 32 thousand deaths due to this disease. Despite the availability of verified methods to diagnose Covid-19, Polymerase Chain Reaction (PCR) or Real Time-PCR (RT-PCR) tests tend to generate false positives and negatives between 30% and 40%. Therefore, helping traditional methods to make an accurate clinical diagnosis, using lung radiographs as input data, represents a radical change in the detection of Covid-19, since it is a much more comfortable alternative for the patient and, more importantly, increases the level of accuracy while reducing false positive and negative rates. The present Systematic Literature Review (SLR), which is based on Barbara Kitchenham's methodology, seeks to support the creation of a model based on Convolutional Neural Network (CNN) architecture, capable of analyzing pulmonary radiographs for the diagnosis of Covid-19. As a result, it was possible to answer the three research questions posed, which served to delimit the present study, for which 41 related works (TR) were analyzed, which focused on different diagnostic methods based on Artificial Intelligence (AI), however 16 of these TR referred to the use of CNN for the diagnosis of Covid-19 through the analysis of computed tomography (CT) and pulmonary radiographs (X-rays), the latter being the most viable option to apply it in our environment, due to the availability of data. Furthermore, the use of resources by these methods is affordable, either locally using the Nvidia Graphics Processing Unit (GPU) and RAM memory greater than 8GB as a base, or using cloud processing using Google Colab.

Keywords—Diagnostics, Covid-19, CNN, VGG16, Lung radiographs, X-rays.

INTRODUCCIÓN

En diciembre del año 2019, la Organización Mundial de la Salud (OMS) recibió reportes de pacientes que presentaban cuadros de neumonía aguda causados por un patógeno de origen desconocido, proveniente de la ciudad de Wuhan, en la República Popular China (H Yao et al., 2020). A principios de enero, las autoridades del país asiático identificaron la causa de dicha enfermedad y la catalogaron como una nueva cepa de coronavirus desconocida hasta la fecha.

Dicha sepa era provocada por el virus SARS-COV-2, perteneciente a las variaciones de coronavirus (CoV), debido a la apariencia externa de la membrana que la recubre. Este tipo de virus por lo general, es muy común en especies animales como ganado, camellos, murciélagos y gatos, aunque en ocasiones se puede transmitir entre humanos y propagarse entre su población (propagación zoonótica), tal como ocurrió en el año 2012, tras la aparición del MERS-CoV, en el Reino de Arabia Saudí, dejando como resultado, alrededor de 858 fallecidos (Sahan et al., 2021). No obstante, esta última (SARS-CoV-2), está teniendo efectos mucho más devastadores en la especie humana, debido a su considerable capacidad de transmisión entre humanos, y a su elevada tasa de mortalidad. Por tal razón, los organismos de salud han dispuesto de medidas sanitarias e incitaron a una respuesta por parte de los países más afectados, con el fin de controlar y mitigar los impactos de la pandemia (S D S Dass et al., 2020).

Pese a ello, la pandemia causada por el COVID-19, se ha expandido a todos los continentes, dejando tras de sí, cerca de 219 millones de contagios, de los cuales 4,5 millones han muerto, según cifras oficiales manejadas por (Google-Noticias, 2021). Según esta misma fuente, en nuestro país, se estima que existen 508 mil casos confirmados y aproximadamente 32 mil muertes. Aún cuando se ha desarrollado 13 variedades de vacunas distintas (OMS, 2021), el virus SARS-COV-2, sigue suponiendo una potencial amenaza a la salud, sobre todo en países en los que a pesar de todas las medidas implementadas para su contención y mitigación, existe una escasez de equipo médico para el diagnóstico oportuno del virus.

Acorde con lo mencionado anteriormente es preciso recalcar que, la capacidad para tomar decisiones clínicas inmediatas garantizará el uso eficiente de los recursos sanitarios, lo cual es un punto clave para compensar el creciente número de contagios y reducir al máximo la curva de infectados y fallecidos. Y es por ello que en la presente Revisión Sistemática de Literatura RSL, la cual, se llevó a cabo mediante la metodología de Bárbara Kitchenham, ha permitido recolectar un número considerable de artículos, los cuales abordan temas relacionados con el diagnóstico de Covid-19 mediante la aplicación de técnicas y métodos alternativos, mismos que nos han permitido corroborar la aplicación de la IA en este tipo de procedimientos y a la vez, optar por el que mejor se adapta a los recursos y características del entorno que nos rodea, siendo los modelos de redes neuronales convolucionales (CNN) aplicados al reconocimiento de patrones en radiografías pulmonares los que alcanzaron un mayor nivel de precisión.

A continuación, se presenta el desarrollo del presente estudio, el cual se realizó en diferentes secciones como: la sección de Materiales y Métodos, donde se han definido las fa-

ses que propone Barbara Kitchenham para realizar revisiones de literatura, posteriormente, se ha detallado el proceso de cada una de estas fases. En la sección de Resultados, se detallan las salidas de los procesos aplicados anteriormente, resaltando sobre todo los trabajos relacionados, los cuales se analizan, explican e interpretan de forma más detallada en la sección de Discusión, y finalmente, se plantean las Conclusiones obtenidas durante la realización de la presente RSL.

MATERIALES Y MÉTODOS

La realización de la revisión sistemática de literatura (RSL), se basa en el proceso establecido en la metodología de Bárbara Kitchenham (Kitchenham Charters, 2007), dicho proceso consta de tres fases fundamentales:

- Planificar la revisión
 - Especificar preguntas de investigación
 - Desarrollar protocolo de revisión
 - Validar protocolo de revisión
- Conducir la revisión
 - Identificar fuentes/estudios relevantes
 - Seleccionar estudios primarios
 - Evaluar la calidad de los estudios
 - Extraer datos requeridos
 - Sintetizar datos
- Documentar la revisión
 - Escribir informe de revisión
 - Validar informe

Aunque algunas de las tareas de estas fases no son obligatorias, como por ejemplo:

- Es opcional la puesta en marcha de una RSL, ya que depende de la revisión sistemática que se está haciendo sobre una base comercial.
- Evaluar el protocolo de revisión y la evaluación del informe, son opcionales y dependen de los procedimientos de garantía de calidad decididas por el encargado de la revisión sistemática.

Considerando los puntos anteriormente expuestos, en la presente RSL, se aprovechó la flexibilidad de la metodología propuesta por Kitchenham, quien depende de la necesidad y el alcance que el investigador requiera y crea conveniente para la obtención de resultados y posterior publicación. De acuerdo a esto, en la Tabla 1, se presentan las fases y tareas que fueron consideradas para el presente trabajo de investigación:

RESULTADOS

A. Planificación de la revisión

Identificación de la necesidad de una revisión.

Con la presente RSL, se busca determinar las técnicas y métodos utilizados para la detección de Covid-19 (SARS-CoV-2), de otras enfermedades con sintomatología similar

Tabla 1: Proceso de RSL basado en la metodología de Bárbara Kitchenham.

Fases	Tareas
Planificación de la revisión	1. Identificar la necesidad de una revisión. 2. Especificar preguntas de investigación. 3. Desarrollar protocolo de revisión.
Conducción de la revisión	1. Identificar fuentes/ estudios relevantes. 2. Seleccionar estudios primarios. 3. Sintetizar datos
Revisión de informes	Escribir informe de revisión.

Tabla 2: Preguntas de investigación para la RSL

Preguntas de investigación
P1 ¿Cuáles son los enfoques existentes basados en Inteligencia Artificial (IA) o Machine Learning (ML), para la detección de Covid-19 (SARS-CoV-2), gripe o neumonía pulmonar?
P2 ¿Cuáles son los métodos, modelos o herramientas más precisos empleados hasta la fecha, para el diagnóstico de Covid-19?
P3 ¿Cuáles son los recursos necesarios empleados por los métodos de IA para la detección de Covid-19?

tales como, la gripe y la neumonía pulmonar, mediante la aplicación de técnicas de aprendizaje automático o Machine Learning y de esta manera, determinar la viabilidad de diseño y creación de un sistema capaz de diagnosticar, con un nivel de eficiencia aceptable, si el paciente (usuario) es portador de una de las enfermedades antes mencionadas. Todo esto con la finalidad de optar por el método más eficiente, tomando en cuenta los recursos disponibles y sobre todo, basarnos en trabajos los cuales nos guíen para la delimitación de nuestra investigación

Especificación de las preguntas de investigación.

Como un mecanismo para guiar el desarrollo de la RSL, se ha planteado una serie de preguntas de investigación, de tal forma que el presente trabajo se enfoque en dar respuesta a estas preguntas, manteniendo siempre la misma perspectiva y enfoque, estas preguntas se presentan en la Tabla 2.

Estrategias de búsqueda

Según Petticrew y Roberts (Petticrew Roberts, 2008), es aconsejable utilizar métodos que permitan recopilar evidencia de manera estructurada, para ello recomiendan utilizar el método PICOC:

- Population: ¿Quién?
- Intervention: ¿Qué o cómo?
- Comparison: ¿Comparado con qué?

Tabla 3: Cadenas de búsqueda para cada una de las bibliotecas virtuales.

Bibliotecas virtuales	Cadenas de búsqueda
ACM Digital Library	[Publication Title: machine learning" "model" "expert system" "expert systems] AND [Abstract: "covid-19 "] AND [[Publication Title: "diagnosis covid-19"] OR [Publication Title: "diagnose covid-19"] OR [Publication Title: "covid-19"]] AND [Abstract: "diagnosis" "disease" "identification" AND [[Abstract:"machine learning"] OR [Abstract: "model"] OR [Abstract: "expert system"] OR [Abstract: "expert systems"] AND [Publication Date: (01/01/2019 TO 01/31/2021)]
IEEE Digital Library	(((((("Document Title":Covid-19) AND "Abstract": Machine learning) AND "Abstract":Model) OR "Abstract": Artificial intelligence) AND "Abstract": :Diagnos) OR "Abstract":Identification*) AND("Document Title":Machine learning) OR "Document Title":Artificial intelligence AND Co- vid*) OR "Document Title": Model) AND "Abstract":Covid-19)
Scopus	TITLE (("machine learning" OR "artificial intelligence" OR "expert system" OR "intelligence systems") AND ("covid19" OR "covid-19") AND (diagnos* OR identification OR disease))

- Outcomes: ¿Qué estás tratando de lograr / mejorar?
- Context: ¿En qué tipo de organización / circunstancias?

Este método, se utiliza para describir una estructura basada en los cinco componentes antes mencionados, de tal forma que nos permita definir la cadena de búsqueda. No obstante, de la nemotécnica PICOC, para la presente RSL no se considera el criterio de Comparación (Silahudin et al., 2020), siendo únicamente cuatro componentes: Population (P), Intervention (I), Outcomes (O) y Context (C), los utilizados para este fin. Así mismo, para una mejor organización y selección de todos los resultados, se utilizó la herramienta Parsifal, la cual sirve de soporte para realizar RSL en el contexto de la Ingeniería del Software. Gracias a esta herramienta, hemos podido dar seguimiento a la RSL en cada una de sus etapas, obteniendo así, resultados mucho más óptimos.

Fuentes bibliográficas.

Las fuentes bibliográficas seleccionadas fueron tomadas de las siguientes bibliotecas virtuales:

- ACM Digital Library (<https://dl.acm.org/>)
- IEEE Digital Library (<https://www.ieee.org/>)
- Scopus (<http://www.scopus.com>)

Definir palabras claves para el problema de estudio

Basándonos en la definición de los criterios PICOC, se ha obtenido las siguientes palabras claves, las cuales nos han permitido construir las cadenas de búsqueda. Las palabras clave en cuestión son:

- Artificial intelligence
- Covid-19
- Diagnosis
- Machine learning
- Expert system
- Neural network

Cadenas de búsqueda

Las cadenas de búsqueda fueron construidas en base a las palabras clave definidas anteriormente. Estas cadenas se aplicaron de acuerdo a cada biblioteca virtual seleccionada: ACM Digital Library, IEEE Digital Library y Scopus. Las cadenas finales se presentan en la Tabla 3.

Criterios de inclusión

Se consideró como criterios de inclusión, los siguientes:

- Artículos o libros con un año de publicación mayores al 2019.
- Artículos o libros en inglés o español.
- El artículo habla sobre los métodos de IA para identificar o diagnosticar Covid-19.

Criterios de exclusión

Se consideró como criterios de exclusión, los siguientes:

- Artículos con un año de publicación menor al 2019.
- El modelo no reconoce o diagnostica Covid-19.
- Métodos y técnicas difusos o con ambigüedad.

B. Conducción de la revisión

Identificación de la investigación

El objetivo de la presente RSL, es dar contestación a las preguntas de investigación, mediante la búsqueda de estudios primarios que nos ayuden con información relacionada con las herramientas basadas en IA empleadas para diagnosticar Covid-19 o similares, debido a que es un tema relativamente nuevo en lo que respecta al diagnóstico de esta enfermedad usando técnicas basadas en IA.

Razón por la cual, la selección de los estudios primarios, se realizó contrastando los resultados de varias fuentes de tal manera que, la información sea de calidad y se enfoque únicamente en el objetivo de la presente RSL.

Para realizar la selección de los estudios se ha seguido el proceso que se muestra en la Figura 1.

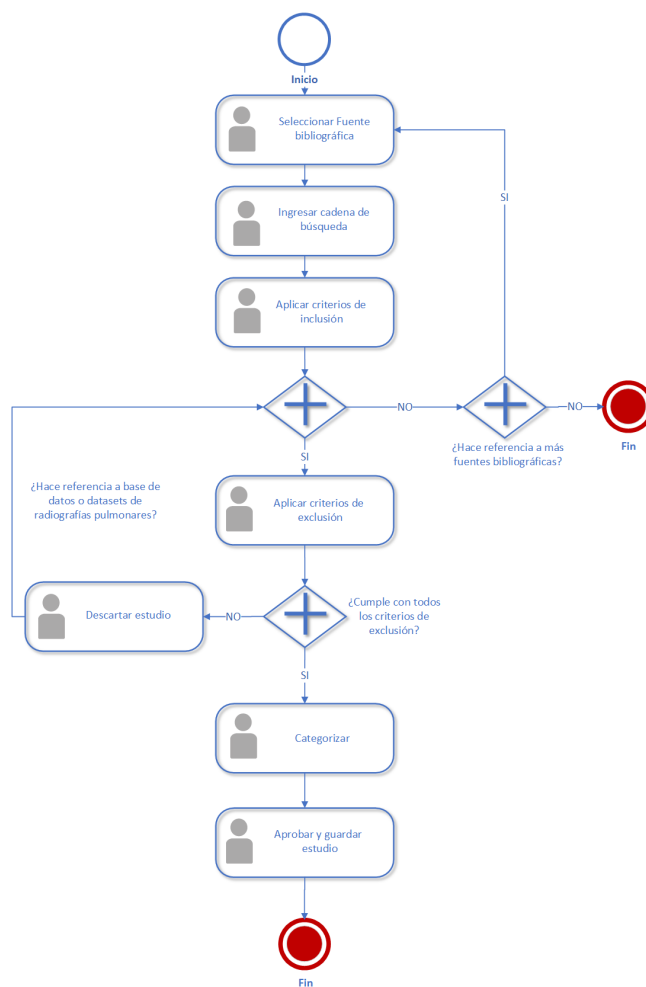


Fig. 1: Diagrama de actividades para el proceso de selección de artículos.

Los estudios obtenidos en cada una de las bibliotecas virtuales, se presentan en la Tabla 4, así como los trabajos que fueron seleccionados por cada una de ellas. Estos estudios o trabajos seleccionados, corresponden a aquellos que cumplieron con todos los criterios de selección establecidos.

Tabla 4: Total de estudios encontrados y seleccionados por cada una de las bibliotecas virtuales.

Fuente	Encontrados	Seleccionados
ACM Digital Library	19	6
IEEE Digital Library	38	22
Scopus	45	13
Total	102	49

Tal como se puede evidenciar en la tabla anterior, se obtuvo un total de 102 trabajos relacionados (TR), los cuales fueron procesados de acuerdo al diagrama expuesto en la Fig. 1. Del total de TR, tras realizar su respectivo análisis de selección, fueron aprobados un total de 49 artículos, mismos que cumplían con todos los criterios de selección, y lo más importante, contenían información necesaria para la realización de la presente RSL, sentando las bases para futuros trabajos. Estos TR se presentan en la Tabla 5.

Cabe recalcar, que 8 de los 49 artículos seleccionados no

podieron ser analizados a profundidad, debido a que su acceso estaba restringido, por lo que se los clasificó como inaccesibles, y se tomó la decisión de no incluirlos en la tabla final de TR.

Síntesis de datos

Cada TR fue analizado con la finalidad de identificar si contenía algún aporte significativo que nos ayudase a obtener información relacionada con los modelos de IA utilizados para el diagnóstico de Covid-19. Así mismo, nos permitió extraer información adicional como los requerimientos del modelo, su nivel de precisión, su factibilidad de implementación y el banco de datos utilizado. Finalmente, esta síntesis nos ha permitido dar contestación a las preguntas de investigación planteadas en la Tabla 2.

¿Cuáles son los enfoques existentes basados en Inteligencia Artificial (IA) o Machine Learning (ML), para la detección de Covid-19 (SARS-CoV-2), gripe o neumonía pulmonar?

Según los artículos TR02, TR05, TR13, TR17, TR20, TR21, TR22, TR24, TR25, TR26, TR27, TR28, TR29, TR33, TR37 y TR40, proponen la creación de herramientas basadas en diferentes enfoques para el diagnóstico rápido y eficiente de Covid-19. Estos enfoques se basan en modelos que van desde el análisis de tomografías computarizadas (TC) e imágenes de rayos X TR01, TR05, TR07, TR10, TR12, TR13, TR20 TR24 y TR41, el análisis de sangre propuestos en TR21 y TR38, el análisis de voz TR13, TR24 y TR10, incluso TR30, recomienda la implementación de un modelo para el diagnóstico de Covid-19, a partir de los síntomas que el paciente ingresa en el sistema. Otros artículos como el TR3 y TR26, proponen la construcción de un novedoso sistema que unifica la IA y el internet de las cosas (IoT), con el fin de proveer de herramientas de diagnóstico asequibles, tanto para profesionales de la salud y para quienes no lo son.

¿Cuál es el enfoque de aplicación para contrarrestar el Covid-19?

Más de la mitad de los artículos y trabajos relacionados, apuntan a que los métodos para el diagnóstico basados en el análisis de tomografías computarizadas (TC) y radiografías pulmonares (rayos X) son los que mayor precisión arrojaron en la fase de evaluación de los modelos. De estos dos últimos, el más asequible, considerando su disponibilidad y factibilidad, es el método que emplea rayos X para el diagnóstico de Covid-19, según los artículos TR01, TR07, TR10, TR13, TR16 y TR24.

¿Cuáles son los métodos, modelos o herramientas más precisos empleados hasta la fecha, para el diagnóstico de Covid-19?

Referente a las herramientas, métodos y modelos de diagnóstico más utilizados, en los trabajos relacionados RT02, TR07, TR11, TR16, TR18, TR23, TR24, TR30, TR31, TR32, TR35 y TR41, se han implementado modelos basados en Redes Neuronales Convolucionales (CNN) para el análisis

de imágenes médicas, mismos que han obtenido los mejores resultados en su fase de evaluación. Este tipo de modelos, junto con aquellos que se basan en el diagnóstico a partir de la sintomatología del paciente, como en el caso de los artículos TR08 y TR34, presentan una mayor viabilidad de aplicación, lo cual se ratifica en las revisiones y comparaciones de los modelos existentes TR08 y TR11, en donde se establece un análisis comparativo entre los diferentes modelos empleados para el diagnóstico de Covid-19, llegando a la conclusión de que la implementación de modelos basados en redes neuronales convolucionales CNN, poseen una mayor cantidad de aceptación y un mayor nivel de precisión, convirtiéndolos así, en los modelos basados en IA más factibles para implementar.

De manera que, ¿Cuál es el modelo, método o herramienta más precisa utilizada para identificar el virus del Covid-19? Considerando la gran variedad de modelos existentes, se resaltan aquellos que están basados en CNN y que han tomado como referencia su arquitectura basada en capas para la interpretación de patrones existentes en las CT y las imágenes de rayos X (imágenes médicas). De esta forma, imita el entrenamiento médico, pero con una curva de aprendizaje mucho mayor, dado que este tipo de modelos son capaces de identificar los patrones existentes en un conjunto enorme de datos que cualquier humano, porque el enfoque de CNN tiene resultados más precisos y en periodos de tiempo mucho más cortos. La precisión y sensibilidad de los modelos implementados y descritos en los artículos TR01, TR02, TR07, TR11, TR14, TR16, TR17, TR25, TR26, TR28, TR29, TR30, TR31, TR32, TR36 y TR41, existe un umbral aceptable que supera fácilmente el 90% de precisión, siendo TR02, TR11, TR16, TR28, TR28, TR31, TR32 y TR4, los que mayor nivel de precisión presentan, aproximadamente un 98%.

¿Cuáles son los recursos necesarios empleados por los métodos de IA para la detección de Covid-19?

Tomando como referencia aquellos artículos en los cuales el nivel de precisión supera el 90%, se da contestación a la última pregunta de investigación, ¿Cuáles son los requisitos para su implementación?

Empezando por el artículo TR02, el cual propone la creación de un sistema potenciado por el aprendizaje automático, para el diagnóstico de COVID-19 aplicando un modelo basado en CNN llamado DeepLab-v3+. Este modelo requiere el tratamiento previo y el aumento de los datos, de tal manera, que los pequeños detalles, las texturas y el contraste de las imágenes permitan una mayor precisión del diagnóstico. Así mismo TR11, propone una red neuronal convolucional profunda para clasificar un conjunto de imágenes médicas y diagnosticar enfermedades como la neumonía y la COVID-19. Para ello utiliza una máquina de vectores de soporte lineal, VGG-16 e InceptionV3 para modelos de redes neuronales convolucionales que son utilizados para obtener los resultados, además, se utilizan algoritmos de aprendizaje como SVM, algoritmo Naive Bayes y el algoritmo de bosque aleatorio. TR16 por su parte, propone la utilización de modelos prediseñados de CNN (VGG-16 o VGG-19) para la creación de un modelo propio constituido por 15 capas (una menos que la VGG-16 que contiene 16 capas).

Tabla 5: Trabajos relacionados aprobados

Código	Título	Referencia
TR01	A deep learning framework to detect Covid-19 disease via chest X-ray and CT scan images.	(Kamil, 2021)
TR02	A Deep Learning Prognosis Model Help Alert for COVID-19 Patients at High-Risk of Death: A Multi-Center Study	(Meng et al., 2020)
TR03	A multi-task pipeline with specialized streams for classification and segmentation of infection manifestations in COVID-19 scans	(El-bana et al., 2020)
TR04	A Novel AI-enabled Framework to Diagnose Coronavirus COVID-19 using Smartphone Embedded Sensors: Design Study	(Maghded et al., 2020)
TR05	A Novel Medical Diagnosis model for COVID-19 infection detection based on Deep Features and Bayesian Optimization	(Nour et al., 2020)
TR06	A novel perceptual two-layer image fusion using deep learning for imbalanced COVID-19 dataset	(Elzeki et al., 2021)
TR07	A Radiomics Signature to Quantitatively Analyze COVID-19-Infected Pulmonary Lesions	(Qiu et al., 2021)
TR08	A Survey on how computer vision can response to urgent need to contribute in COVID-19 pandemics	(Gazzah et al., 2020)
TR09	Accelerating detection of lung pathologies with explainable ultrasound image analysis	(Born et al., 2021)
TR10	An Attention Mechanism with Multiple Knowledge Sources for COVID-19 Detection from CT Images	(Nguyen et al., 2020)
TR11	Approaches based on artificial intelligence and the internet of intelligent things to prevent the spread of COVID-19: Scoping review	(Adly et al., 2020)
TR12	Artificial Intelligence and COVID-19: Deep Learning Approaches for Diagnosis and Treatment	(Jamshidi et al., 2020)
TR13	Artificial Intelligence applied to chest X-Ray images for the automatic detection of COVID-19. A thoughtful evaluation approach	(Arias-Londoño et al., 2020)
TR14	Artificial intelligence technology for diagnosing COVID-19 cases: A review of substantial issues	(Alsharif & Qurashi, 2020)
TR15	Benchmarking Methodology for Selection of Optimal COVID-19 Diagnostic Model Based on Entropy and OPSIS Methods	(Mohammed et al., 2020)
TR16	CCBlock: An Effective Use of Deep Learning for Automatic Diagnosis of COVID-19 Using X-Ray Images	(Al-Bawi et al., 2020)
TR17	Chest X-ray image analysis and classification for COVID-19 pneumonia detection using deep CNN	(Gao, 2020)
TR18	Computer aid screening of COVID-19 using X-ray and CT scan images: An inner comparison	(Sethy et al., 2021)
TR19	COVID CT-Net: Predicting Covid-19 from chest CT images using attentional convolutional network	(Yazdani et al., 2020)
TR20	COVID-19 detection based on deep learning and artificial bee colony	(Sahan et al., 2021)
TR21	Covid-19 Detection by Optimizing Deep Residual Features with Improved Clustering-Based Golden Ratio Optimizer	(Chattopadhyay et al., 2021)
TR22	COVID-19 detection on chest X-Ray and CT Scan images using multi-image augmented deep learning model	(Purohit et al., 2020)
TR23	COVID-19 Disease Diagnosis using Smart Deep Learning Techniques	(Kavitha et al., 2020)
TR24	Covid19 Identification from Chest X-ray Images Using Machine Learning Classifiers with GLCM Features	(Thepade et al., 2020)
TR25	CT Quantification and Machine-learning Models for Assessment of Disease Severity and Prognosis of COVID-19 Patients	(Cai et al., 2020)
TR26	Deep learning analysis provides accurate COVID-19 diagnosis on chest computed tomography	(Javor et al., 2020)
TR27	Deep Learning in Detection and Diagnosis of Covid-19 using Radiology Modalities: A Systematic Review	(Review, 2020)
TR28	Detection of coronavirus disease (COVID-19) from X-ray images using deep convolutional neural networks	(KUTLU & CAMGÖZLÜ, 2021)
TR29	Diagnosis of Coronavirus Disease 2019 (COVID-19) with Structured Latent Multi-View Representation Learning	(Kang et al., 2020)

Tabla 5: Trabajos relacionados aprobados

Código	Título	Referencia
TR30	Expert system for early diagnosis of covid-19	(Sharana Dharshikgan Suresh Dass et al., 2020)
TR31	Heg.IA: an intelligent system to support diagnosis of Covid-19 based on blood tests	(de Freitas Barbosa et al., 2021)
TR32	Inf-Net: Automatic COVID-19 Lung Infection Segmentation from CT Images	(de Freitas Barbosa et al., 2021)
TR33	Intelligent Internet of Things and Advanced Machine Learning Techniques for COVID-19	(Chakraborty & Abougreen, 2018)
TR034	Longitudinal proteomic profiling of high-risk patients with COVID-19 reveals markers of severity and predictors of fatal disease	(Gisby et al., 2020)
TR35	Machine learning-based prediction of COVID-19 diagnosis based on symptoms	(Zoabi et al., 2021)
TR36	Model expert system for diagnosis of COVID-19 using naïvebayes classifier	(Silahudin et al., 2020)
TR37	Multi-task contrastive learning for automatic CT and X-ray diagnosis of COVID-19	(M. D. Li et al., 2021)
TR38	Severity Detection for the Coronavirus Disease 2019 (COVID-19) Patients Using a Machine Learning Model Based on the Blood and Urine Tests	(Haochen Yao et al., 2020)
TR39	The value of artificial intelligence and imaging diagnosis in the fight against COVID-19	(Zhang et al., 2021)
TR40	Transfer learning to detect COVID-19 automatically from X-ray images, using convolutional neural networks	(Tareh et al., 2020)
TR41	Using machine learning of clinical data to diagnose COVID-19: A systematic review and meta-analysis	(W. T. Li et al., 2020)

En términos de rendimiento VGG-16, es una red con baja complejidad computacional debido a las pequeñas dimensiones de sus filtros, exactamente 9 píxeles por cada una de las 16 capas de aprendizaje que la componen.

Al igual que en los artículos anteriores, TR28 propone la implementación de un modelo basado en redes neuronales convolucionales CNN para solventar el problema actual que presentan las pruebas RT-PCR al diagnosticar COVID-19. Este modelo está enfocado en el diagnóstico a partir del análisis de radiografías de tórax, además, utiliza SVM para clasificar cada una de las clases de radiografías existentes.

En lo que respecta al modelo de aprendizaje profundo utilizado en este trabajo, el VGG-16 que también se menciona en el artículo TR29, consta de diferentes capas de agrupación máxima, de activación y convolución completamente conectadas, conformando un total de 21 capas, pero solo 16 de peso. Estas capas adicionales están conformadas a su vez por 5 capas de agrupación máxima, 3 de densidad y 13 de convolución.

Además, para su construcción en la mayoría de los TR se ha empleado Python como lenguaje de programación, y en lo que a hardware corresponde, se recomienda utilizar un CPU con una capacidad de procesamiento igual o superior al AMD Ryzen 53600x o por el lado de Intel, considerar las opciones a partir del Core i5-9400f en adelante, para la unidad de procesamiento gráfico o GPU, se recomienda el uso de una NVIDIA GTX 1080 o superior, además como requisito mínimo, usar 16 GB de RAM para aprovechar al máximo la capacidad de procesamiento de las CPU y la GPU.

DISCUSIÓN

La presente RSL tuvo como propósito determinar las técnicas, métodos o modelos utilizados en la detección de Covid-19 (SARS-CoV-2) de otras enfermedades con sintomatología similar tales como la gripe y el resfriado mediante la aplicación de técnicas de aprendizaje automático o Machine Learning, y de esta manera determinar la viabilidad de diseño y creación de un sistema capaz de diagnosticar con un nivel de eficiencia aceptable, si el paciente (usuario) es portador de una de las enfermedades antes mencionadas.

De los resultados obtenidos tras el análisis de los TR, en la mayoría de ellos, contienen métodos innovadores basados en IA para el diagnóstico de Covid-19. Métodos como el análisis de sangre o el análisis de voz comprenden una complejidad y reto mayor, sobre todo estos métodos no garantizan una fiabilidad mayor al 90%, que es lo que esperamos obtener. Así mismo, el uso de un sistema que utiliza el procesamiento de lenguaje natural para el diagnóstico de la enfermedad, podría ser una solución aceptable y aplicable, considerando los recursos y la población a la que está dirigida este sistema, el único inconveniente tras el análisis de TR3 y TR26, que son los artículos que hacen mención a esta alternativa, es la variedad de síntomas que presenta el Covid-19, muchos de ellos no se presentan entre los pacientes infectados, por lo que fácilmente se lo puede confundir con otro tipo de afección pulmonar como la gripe o neumonía. Finalmente, el uso de CNN para el diagnóstico de Covid-19 usando imágenes médicas, se ha considerado como una alternativa viable para implementar, ya que los

recursos con los cuales disponemos, sumado al nivel de precisión alcanzado en los TR que hacen mención a este método, sustentan nuestra elección.

En términos de precisión, la CNN, específicamente aquellos modelos basados en la arquitectura VGG-16, presentan un nivel de precisión superiores al 90 %, llegando a alcanzar como máximo el 98 %. Estos datos, sumados a los recursos que los TR emplearon para su realización, nos permitieron optar por esta arquitectura frente a otros modelos como InceptionV3 o ResNet50, los cuales se mantienen bajo el umbral del 95 % en el mejor de los casos. Ahora bien, una vez se estableció el modelo y arquitectura, fue necesario delimitar el tipo de imagen médica más factible utilizada en la fase de construcción del modelo, siendo las TC y las radiografías pulmonares las utilizadas para este fin.

Uno de los factores tomados en cuenta, fue la disponibilidad de los datos, y el segundo su accesibilidad, ya que muchos de los bancos de datos utilizados en los TR no estaban disponibles o simplemente, no se pudo acceder a ellos, no obstante, trabajos relacionados como TR40, hacía referencia a una base de datos la cual contenía un gran número de radiografías pulmonares listas para ser utilizadas. A pesar de que las TC son capaces de captar un mayor número de datos en comparación a las radiografías pulmonares, las TC son mucho más costosas de realizar debido a los equipos especiales que se emplean para este fin, así mismo, tras realizar un análisis del entorno en el cual se puede implementar, no disponen de estos equipos, pero si disponen de máquinas de Rayos X. Además la RSL justifica y ratifica que los modelos basados en CNN presentan una mayor eficiencia al momento de implementar modelos capaces de diagnosticar Covid-19, alcanzando un porcentaje de precisión mayor al 95 % en la mayoría de los casos.

Por último, los recursos utilizados por los modelos basados en CNN, son asequibles para una eventual implementación, tanto a nivel de hardware como de software, existen alternativas Open Source como Google Colab, la cual nos brinda recursos para desplegar este tipo de modelos en caso de que los recursos disponibles de forma local no sean suficientes.

CONCLUSIONES

Tras el análisis de los enfoques alternativos de IA como procesamiento de lenguaje natural, análisis de sangre y sinomatología para el diagnóstico de Covid-19 desarrollados en los TR, se concluye que los métodos basados en el análisis de imágenes médicas como tomografías computarizadas (TC) y rayos X, son la opción más viable para una eventual implementación. Siendo las redes neuronales convolucionales la rama de la IA con la que mejores resultados se obtuvieron, un promedio superior al 90 %, superando así, el nivel de precisión de las pruebas tradicionales PCR/RT-PCR.

Los modelos orientados al diagnóstico de Covid-19 mediante el análisis de imágenes médicas utilizando redes neuronales convolucionales, presentan los mejores resultados, sobre todo en la fase de evaluación, siendo VGG-16 el más preciso, sobrepasando el 95 % con respecto a modelos como InceptionV3 o DeepLab-v3+. Además, el uso de modelos preentrenados (VGG-16) garantiza una precisión superior al 30 % respecto a las pruebas tradicionales RT-PCR.

Los recursos utilizados para la implementación del modelo basado en redes neuronales convolucionales, dependerán en gran medida de la configuración de sus hiperparámetros y los drivers disponibles para dicho fin. Aspectos como disponibilidad de drivers y librerías son resaltados en los TR debido a la compatibilidad de los mismos con los componentes de hardware, sobre todo con las GPU Nvidia usadas en la fase de entrenamiento.

AGRADECIMIENTOS

Mi agradecimiento más sincero a la Universidad Nacional de Loja, a todos sus docentes los cuales me formaron tanto intelectual y profesionalmente.

REFERENCIAS

Adly, A. S. A. S., Adly, A. S. A. S., y Adly, M. S. (2020). Approaches Based on artificial intelligence and the internet of intelligent things to prevent the spread of COVID-19: Scoping review. *Journal of Medical Internet Research*, 22(8). <https://doi.org/10.2196/19104>

Al-Bawi, A., Al-Kaabi, K., Jeryo, M., y Al-Fatlawi, A. (2020). CCBLOCK: an effective use of deep learning for automatic diagnosis of COVID-19 using X-ray images. *Research on Biomedical Engineering*. <https://doi.org/10.1007/s42600-020-00110-7>

Alsharif, W., y Qurashi, A. (2020). Effectiveness of COVID-19 diagnosis and management tools: A review. *Radiography*. <https://doi.org/10.1016/j.radi.2020.09.010>

Arias-Londoño, J. D., Gomez-Garcia, J. A., Moro-Velazquez, L., y Godino-Llorente, J. I. (2020). Artificial Intelligence applied to chest X-Ray images for the automatic detection of COVID-19. A thoughtful evaluation approach.

Born, J., Wiedemann, N., Cossio, M., Buhre, C., Brändle, G., Leidermann, K., Aujayeb, A., Moor, M., Rieck, B., y Borgwardt, K. (2021). Accelerating detection of lung pathologies with explainable ultrasound image analysis. *Applied Sciences (Switzerland)*, 11(2), 1–23. <https://doi.org/10.3390/app11020672>

Cai, W., Liu, T., Xue, X., Luo, G., Wang, X., Shen, Y., Fang, Q., Sheng, J., Chen, F., y Liang, T. (2020). CT Quantification and Machine-learning Models for Assessment of Disease Severity and Prognosis of COVID-19 Patients. *Academic Radiology*, 27(12), 1665–1678. <https://doi.org/10.1016/j.acra.2020.09.004>

Chakraborty, C., y Abougreen, A. (2018). Intelligent Internet of Things and Advanced Machine Learning Techniques for COVID-19. *EAI Endorsed Transactions on Pervasive Health and Technology*, 168505. <https://doi.org/10.4108/eai.28-1-2021.168505>

Chattopadhyay, S., Dey, A., Singh, P. K., Geem, Z. W., y Sarkar, R. (2021). Covid-19 Detection by Optimizing Deep Residual Features with Improved Clustering-

Based Golden Ratio Optimizer. *Diagnostics*, 11(2), 315. <https://doi.org/10.3390/diagnostics11020315>

Dass, S D S, Meskaran, F., y Saeedi, M. (2020). Expert system for early diagnosis of covid-19. *International Journal of Current Research and Review*, 12(22), 162–165. <https://doi.org/10.31782/IJCRR.2020.122227>

Dass, Sharana Dharshikgan Suresh, Meskaran, F., y Saeedi, M. (2020). Expert system for early diagnosis of covid-19. *International Journal of Current Research and Review*, 12(22), 162–165. <https://doi.org/10.31782/IJCRR.2020.122227>

de Freitas Barbosa, V. A., Gomes, J. C., de Santana, M. A., Albuquerque, J. E. A., de Souza, R. G., de Souza, R. E., dos Santos, W. P. (2021). Heg.IA: an intelligent system to support diagnosis of Covid-19 based on blood tests. *Research on Biomedical Engineering*. <https://doi.org/10.1007/s42600-020-00112-5>

El-bana, S., Al-Kabbany, A., y Sharkas, M. (2020). A multi-task pipeline with specialized streams for classification and segmentation of infection manifestations in COVID-19 scans. *PeerJ Computer Science*, 6, e303. <https://doi.org/10.7717/peerj-cs.303>

Elzeki, O. M., Abd Elfattah, M., Salem, H., Hassani, A. E., Shams, M. (2021). A novel perceptual two layer image fusion using deep learning for imbalanced COVID-19 dataset. *PeerJ Computer Science*, 7, e364. <https://doi.org/10.7717/peerj-cs.364>

Gao, T. (2020). Chest X-ray image analysis and classification for COVID-19 pneumonia detection using deep CNN. In medRxiv. medRxiv. <https://doi.org/10.1101/2020.08.20.20178913> Gazzah, S., Bencharef, O., Marrakech, F. (2020). A Survey on how computer vision can respond to urgent need to contribute in COVID-19 pandemics.

Gisby, J., Clarke, C. L., Medjeral-Thomas, N., Malik, T. H., Papadaki, A., Mortimer, P. M., Buang, N. B., Lewis, S., Pereira, M., Toulza, F., Fagnano, E., Mawhin, M. A., Dutton, E. E., Tapeng, L., Kirk, P., Behmoaras, J., Sandhu, E., McAdoo, S. P., Predecki, M. F., ... Peters, J. E. (2020). Longitudinal proteomic profiling of high-risk patients with COVID-19 reveals markers of severity and predictors of fatal disease. In medRxiv (Vol. 16, Issue 2, p. e0247176). medRxiv. <https://doi.org/10.1101/2020.11.05.20223289>

Google-Noticias. (2021). Coronavirus (COVID-19).

Jamshidi, M., Lalbakhsh, A., Talla, J., Peroutka, Z., Hadjilooei, F., Lalbakhsh, P., Jamshidi, M., Spada, L. L., Mirmozafari, M., Dehghani, M., Sabet, A., Roshani, S., Roshani, S., Bayat-Makou, N., Mohamadzade, B., Malek, Z., Jamshidi, A., Kiani, S., Hashemi-Dezaki, H., y Mohyuddin, W. (2020). Artificial Intelligence and COVID-19: Deep Learning Approaches for Diagnosis and Treatment. *IEEE Access*, 8, 109581–109595.

<https://doi.org/10.1109/ACCESS.2020.3001973>

Javor, D., Kaplan, H., Kaplan, A., Puchner, S. B., Krestan, C., y Baltzer, P. (2020). Deep learning analysis provides accurate COVID-19 diagnosis on chest computed tomography. *European Journal of Radiology*, 133. <https://doi.org/10.1016/j.ejrad.2020.109402>

Kamil, M. Y. (2021). A deep learning framework to detect Covid-19 disease via chest X-ray and CT scan images. *International Journal of Electrical and Computer Engineering*, 11(1), 844–850. <https://doi.org/10.11591/ijece.v11i1.pp844-850>

Kang, H., Xia, L., Yan, F., Wan, Z., Shi, F., Yuan, H., Jiang, H., Wu, D., Sui, H., Zhang, C., y Shen, D. (2020). Diagnosis of Coronavirus Disease 2019 (COVID-19) with Structured Latent Multi-View Representation Learning. *IEEE Transactions on Medical Imaging*, 39(8), 2606–2614. <https://doi.org/10.1109/TMI.2020.2992546>

Kavitha, K. V., Deshpande, S. R., Pandit, A. P., y Unnikrishnan, A. G. (2020). Application of tele-podiatry in diabetic foot management: A series of illustrative cases. *Diabetes and Metabolic Syndrome: Clinical Research and Reviews*, 14(6), 1991–1995. <https://doi.org/10.1016/j.dsx.2020.10.009>

Kitchenham, B., y Charters, S. (2007). Guidelines for performing Systematic Literature Reviews in Software Engineering.

Kutlu, Y., y Cangozlu, Y. (2021). Detection of coronavirus disease (COVID-19) from X-ray images using deep convolutional neural networks. *Natural and Engineering Sciences*, 6(1), 60–74. <https://doi.org/10.28978/nesciences.868087>

Li, M. D., Little, B. P., Alkasab, T. K., Mendoza, D. P., Succi, M. D., Shepard, J.-A. O., Lev, M. H., y Kalpathy-Cramer, J. (2021). Multi-Radiologist User Study for Artificial Intelligence-Guided Grading of COVID-19 Lung Disease Severity on Chest Radiographs. *Academic Radiology*. <https://doi.org/10.1016/j.acra.2021.01.016>

Li, W. T., Ma, J., Shende, N., Castaneda, G., Chakladar, J., Tsai, J. C., Apostol, L., Honda, C. O., Xu, J., Wong, L. M., Zhang, T., Lee, A., Gnanasekar, A., Honda, T. K., Kuo, S. Z., Yu, M. A., Chang, E. Y., Rajasekaran, M. R., y Ongkeko, W. M. (2020). Using machine learning of clinical data to diagnose COVID-19: A systematic review and meta-analysis. *BMC Medical Informatics and Decision Making*, 20(1). <https://doi.org/10.1186/s12911-020-01266-z>

Maghded, H. S., Ghafoor, K. Z., Sadiq, A. S., Curran, K., Rawat, D. B., y Rabie, K. (2020). A Novel AI-enabled Framework to Diagnose Coronavirus COVID-19 using Smartphone Embedded Sensors: Design Study. *Proceedings - 2020 IEEE 21st International Conference on Information Reuse and Integration for Data Science, IRI 2020*, 180–187. <https://doi.org/10.1109/IRI49571.2020.00033>

Meng, L., Dong, D., Li, L., Niu, M., Bai, Y., Wang,

- M., Qiu, X., Zha, Y., y Tian, J. (2020). A Deep Learning Prognosis Model Help Alert for COVID-19 Patients at High-Risk of Death: A Multi-Center Study. *IEEE Journal of Biomedical and Health Informatics*, 24(12), 3576–3584. <https://doi.org/10.1109/JBHI.2020.3034296>
- Mohammed, M. A., Abdulkareem, K. H., Al-Waisy, A. S., Mostafa, S. A., Al-Fahdawi, S., Dinar, A. M., Alhakami, W., Baz, A., Al-Mhiqani, M. N., Alhakami, H., Arbaiy, N., Maashi, M. S., Mutlag, A. A., Garcia-Zapirain, B., De La Torre Diez, I. (2020). Benchmarking Methodology for Selection of Optimal COVID-19 Diagnostic Model Based on Entropy and TOPSIS Methods. *IEEE Access*, 8, 99115–99131. <https://doi.org/10.1109/ACCESS.2020.2995597>
- Nguyen, D. M. H., Nguyen, D. M., Vu, H., Nguyen, B. T., Nunnari, F., y Sonntag, D. (2020). An Attention Mechanism with Multiple Knowledge Sources for COVID-19 Detection from CT Images.
- Nour, M., Cömert, Z., y Polat, K. (2020). A Novel Medical Diagnosis model for COVID-19 infection detection based on Deep Features and Bayesian Optimization. *Applied Soft Computing*, 97. <https://doi.org/10.1016/j.asoc.2020.106580>
- OMS. (2021). Enfermedad por el coronavirus (COVID-19): Vacunas. Onu. OMS, O. M. de la S. (2020). Zoonosis.
- Petticrew, M., y Roberts, H. (2008). Systematic Reviews in the Social Sciences: A Practical Guide. In *Systematic Reviews in the Social Sciences: A Practical Guide*. Blackwell Publishing Ltd. <https://doi.org/10.1002/9780470754887>
- Purohit, K., Kesarwani, A., Kisku, D. R., y Dali, M. (2020). COVID-19 detection on chest X-Ray and CT Scan images using multi-image augmented deep learning model. In *bioRxiv*. <https://doi.org/10.1101/2020.07.15.205567>
- Qiu, J., Peng, S., Yin, J., Wang, J., Jiang, J., Li, Z., Song, H., Zhang, W. (2021). A Radiomics Signature to Quantitatively Analyze COVID-19-Infected Pulmonary Lesions. *Interdisciplinary Sciences: Computational Life Sciences*. <https://doi.org/10.1007/s12539-020-00410-7>
- Ramajo, J., y Márquez, M. Á. (2008). Componentes espaciales en el modelo Shift-Share. Una aplicación al caso de las regiones peninsulares españolas. *Estadística Española*, 50(168), 247–272.
- Review, S. (2020). Deep Learning in Detection and Diagnosis of Covid-19 using Radiology Modalities: A. 1–12.
- Sahan, A. M., Al-Itbi, A. S., y Hameed, J. S. (2021). COVID-19 detection based on deep learning and artificial bee colony. 9(1), 29–36.
- Sethy, P. K., Behera, S. K., Anitha, K., Pandey, C., y Khan, M. R. (2021). Computer aid screening of COVID-19 using X-ray and CT scan images: An inner comparison. *Journal of X-Ray Science and Technology*, 1–14. <https://doi.org/10.3233/xst-200784>
- Silahudin, D., Henderi, y Holidin, A. (2020). Model expert system for diagnosis of COVID-19 using naïve bayes classifier. *IOP Conference Series: Materials Science and Engineering*, 1007(1). <https://doi.org/10.1088/1757-899X/1007/1/012067>
- Taresh, M., Zhu, N., y Ali Ali, T. A. (2020). Transfer learning to detect COVID-19 automatically from X-ray images, using convolutional neural networks. In *medRxiv*. [medRxiv. https://doi.org/10.1101/2020.08.25.20182170](https://doi.org/10.1101/2020.08.25.20182170)
- Thepade, S. D., Bang, S. V., Chaudhari, P. R., y Dindorkar, M. R. (2020). Covid19 Identification from Chest X-ray Images Using Machine Learning Classifiers with GLCM Features. *Electronic Letters on Computer Vision and Image Analysis*, 19(3), 85–97. <https://doi.org/10.5565/REV/ELCVIA.1277>
- Yao, H., Zhang, N., Zhang, R., Duan, M., Xie, T., Pan, J., Peng, E., Huang, J., Zhang, Y., Xu, X., Xu, H., Zhou, F., y Wang, G. (2020). Severity Detection for the Coronavirus Disease 2019 (COVID-19) Patients Using a Machine Learning Model Based on the Blood and Urine Tests. *Frontiers in Cell and Developmental Biology*, 8. <https://doi.org/10.3389/fcell.2020.00683>
- Yao, Haochen, Zhang, N., Zhang, R., Duan, M., Xie, T., Pan, J., Peng, E., Huang, J., Zhang, Y., Xu, X., Xu, H., Zhou, F., y Wang, G. (2020). Severity Detection for the Coronavirus Disease 2019 (COVID-19) Patients Using a Machine Learning Model Based on the Blood and Urine Tests. *Frontiers in Cell and Developmental Biology*, 8(10), 2776–2786. <https://doi.org/10.3389/fcell.2020.00683>
- Yazdani, S., Minaee, S., Kafieh, R., Saedizadeh, N., Sonka, M. (2020). COVID CT-Net: Predicting Covid-19 from chest CT images using attentional convolutional network. *ArXiv*. Zhang, D., Liu, X., Shao, M., Sun, Y., Lian, Q., y Zhang, H. (2021). The value of artificial intelligence and imaging diagnosis in the fight against COVID-19. *Personal and Ubiquitous Computing*. <https://doi.org/10.1007/s00779-021-01522-7>
- Zoabi, Y., Deri-Rozov, S., y Shomron, N. (2021). Machine learning-based prediction of COVID-19 diagnosis based on symptoms. *Npj Digital Medicine*, 4(1). <https://doi.org/10.1038/s41746-020-00372-6>