

Covid 19 identification model using Deep Learning techniques from thorax of lung X-ray images

Huanco-Ramos Fidel, Maestro¹, Apaza-Tarqui Alejandro, Doctor²

^{1,2}Universidad Nacional del Altiplano Puno, Perú, fhuanco@unap.edu.pe, apazatarqui@unap.edu.pe

Abstract.- The pandemic, known as COVID-19, has preoccupied the world since December 2019. To date, it has had an impact on patients. In the fight against this disease, which causes pneumonia and provokes in symptoms from dry cough to fever, tools to urgent requires to provide experts with an efficient diagnosis to identify patients infected with COVID-19. The study aims to determine the diagnostic process model of COVID-19 by applying deep learning techniques from chest X-ray images of patients' lungs. By means of chest X-ray, Have 21165 patient images and those infected with COVID-19 are selected; subsequently, preprocessing and processing is carried out, using convolutional neural network models such as VGG19, DenseNet169, ResNet101 and EfficientNetB0. The performance of the algorithms is also evaluated and compared using algorithm performance metrics. They have been coded using the Python programming language. The best performance results of the four models evaluated are VGG19 DenseNet169 and EfficientNetB0, with 99% precision and recall in the implementation of the algorithms.

Keywords- Deep learning, COVID-19, chest X-ray imaging, pneumonia, convolutional neural networks.

Modelo de identificación de Covid 19 usando técnicas de Deep Learning a partir de imágenes de Rayos X de torax de pulmones

Covid 19 identification model using Deep Learning techniques from thorax of lung X-ray images

Huanco-Ramos Fidel, Maestro¹, Apaza-Tarqui Alejandro, Doctor²

^{1,2}Universidad Nacional del Altiplano Puno, Perú, fhuanco@unap.edu.pe, apazatarqui@unap.edu.pe

Resumen.— La pandemia, conocida como COVID-19, ha preocupado al mundo entero desde diciembre de 2019. Hasta la fecha, ha tenido un impacto en los pacientes. En la lucha contra esta enfermedad, que ocasiona la neumonía y provoca síntomas desde tos seca hasta fiebre, se requieren con urgencia herramientas que faciliten a los expertos un diagnóstico eficiente para identificar pacientes infectados con COVID-19. El estudio tiene como objetivo determinar el modelo de proceso diagnóstico del COVID-19 mediante la aplicación de técnicas de deep learning a partir de imágenes de rayos X del tórax de los pulmones de los pacientes. Por medio de la radiografía de tórax se obtienen las 21165 imágenes de pacientes y se seleccionan las infectadas con COVID-19; posteriormente, se lleva a cabo el preprocesamiento y procesamiento, utilizando modelos de redes neuronales convolucionales como VGG19, DenseNet169, ResNet101 y EfficientNetB0. Asimismo, se evalúa y se compara el rendimiento de los algoritmos mediante métricas de desempeño de algoritmos. Se han codificado utilizando el lenguaje de programación Python. El resultado de mejor desempeño de los cuatro modelos evaluados son VGG19 DenseNet169 y EfficientNetB0, con 99% de precisión y sensibilidad en la implementación de los algoritmos.

Palabras clave-- Aprendizaje profundo, COVID-19, imágenes de rayos X de tórax, neumonía, redes neuronales convolucionales.

Abstract.— The pandemic, known as COVID-19, has preoccupied the world since December 2019. To date, it has had an impact on patients. In the fight against this disease, which causes pneumonia and provokes in symptoms from dry cough to fever, tools to urgent requires to provide experts with an efficient diagnosis to identify patients infected with COVID-19. The study aims to determine the diagnostic process model of COVID-19 by applying deep learning techniques from chest X-ray images of patients' lungs. By means of chest X-ray, Have 21165 patient images and those infected with COVID-19 are selected; subsequently, preprocessing and processing is carried out, using convolutional neural network models such as VGG19, DenseNet169, ResNet101 and EfficientNetB0. The performance of the algorithms is also evaluated and compared using algorithm performance metrics. They have been coded using the Python programming language. The best performance results of the four models evaluated are VGG19 DenseNet169 and EfficientNetB0, with 99% precision and recall in the implementation of the algorithms.

Keywords- Deep learning, COVID-19, chest X-ray imaging, pneumonia, convolutional neural networks.

I. INTRODUCCIÓN

El COVID-19 ha afectado a diversos países y para finales de abril alcanzó más de tres millones de casos confirmados[1]. En diciembre de 2019, se detectaron los primeros casos de enfermedad respiratoria causada por un coronavirus emergente, al que se denominó SARS-CoV-2, los primeros meses de 2020 se ha extendido rápidamente por el mundo con características de pandemia[2]. A mediados de septiembre del año de 2020 ha afectado a 213 países y se aproximaba a 30 millones de casos y a un millón de fallecidos (29.127.686 casos y 927.141 fallecidos, al 13 de septiembre del 2021), y aún era un fenómeno en evolución pues más de 7 millones de casos estaban activos (7.239.064). Incluso, el efecto dejado por la enfermedad en los más de 20 millones de personas recuperadas es un tema activo de investigación[3].

El Perú ha sido uno de los países más afectados por este virus, ya que, según el reporte estadístico del Instituto Nacional de Salud y Centro Nacional de Epidemiología, Prevención y Control de Enfermedades, hasta el 30 de enero del 2021, se han confirmado 474 199 casos de COVID-19 y 16 237 muertos a nivel nacional, cifras sumamente preocupantes para la comunidad médica dedicada a la ciencia. En este marco, afirma que alrededor del 80 % de las personas que adquirieron el virus superan la enfermedad sin requerir tratamiento hospitalario; por lo cual, solo un 20 % de personas con COVID-19 experimentan un cuadro grave con dificultad para respirar, siendo este grupo conformado por personas de la tercera edad, personas con comorbilidades, como hipertensión, problemas cardíacos o pulmonares, diabetes, cáncer, artrosis, gastritis, entre otros[4]. Los pacientes con un riesgo mayor de tener un peor pronóstico al padecer la enfermedad son los pacientes mayores de 60 años, fumadores, con obesidad (IMC>30 kg/m²), hipertensión, enfermedad pulmonar crónica (EPOC, bronquiectasias, fibrosis pulmonar, asma), diabetes, enfermedad cardiovascular crónica (cardiopatía isquémica, insuficiencia cardíaca), accidente cerebrovascular, hepatopatía crónica (cirrosis hepática), enfermedad renal crónica (filtrado glomerular reducido), tumor maligno sólido o neoplasia hematológica activa, inmunosupresión (incluida la farmacológica con esteroides a dosis inmunosupresoras o con agentes biológicos) y embarazadas por el principio de precaución[5]. Todos estos

pacientes acuden recurrentemente a la farmacia a retirar sus medicamentos, al menos una vez al mes, y en caso de comenzar con sintomatología leve, la farmacia puede ser el primer punto de consulta[6].

En este escenario, las radiografías de tórax de pacientes con COVID-19 han demostrado ser una herramienta alternativa importante para el diagnóstico de COVID19 debido a su alta sensibilidad[7]. La precisión del diagnóstico mediante rayos X depende en gran medida de experiencia radiológica[8]. Muchos recomiendan en referencia del diagnóstico a través de un sistema que puede ayudar al médico a examinar por medio de las imágenes pulmonares de los pacientes reducirá la carga diagnóstica para el medico[9]. Esta enfermedad provoca los principales síntomas son: fiebre, dolor de garganta, dolor muscular, tos seca y dificultad respiratoria aguda[10], hasta complicaciones más graves como la insuficiencia respiratoria y neumonía[11]. La rápida difusión del coronavirus y los graves efectos que provoca en seres humanos hacen imperioso un diagnóstico temprano de la enfermedad[5]. Así mismo existen pacientes de tres a más meses tienen complicaciones en los pulmones[12].

El aprendizaje humano es progresivo y se desarrolla a partir de la exposición a situaciones de forma consecutiva, proceso que puede llevar años, en cambio, la adquisición de estos datos por parte de una máquina es mucho más rápida[13]. El aprendizaje automático es una disciplina de la inteligencia artificial que se vale de algoritmos que permiten la identificación de patrones, efectuar predicciones, aprender de los datos y sirve para toma de decisiones, para el caso COVID-19[14]. Los algoritmos son para una sola enfermedad o huella radiológica pueden tener un valor limitado en la práctica clínica real, ya que la interpretación radiológica requiere la evaluación de diversas enfermedades y anomalías[15].

Deep learning es una disciplina de las Ciencias de la Computación englobada dentro del machine learning o aprendizaje automático[16], y además son redes neuronales artificiales, en el que cada capa tiene múltiples neuronas que funcionan de manera similar a las neuronas del cuerpo humano[17]. El desarrollo de aplicaciones de aprendizaje profundo ha sido muy popular en cuanto a tareas de detección de objetos o en tareas de clasificación de imágenes médicas; por ello, utilizar los beneficios de la toma de decisiones médicas basadas en sistemas asistidos por computadora se está volviendo cada vez más una realidad[18]. En este escenario aparece la oportunidad de utilizar estas tecnologías como apoyo a las pruebas estándar para reducir la brecha en infraestructura y aliviar el colapso del sistema sanitario[8]. Por estas razones, se han venido proponiendo distintas metodologías para identificar el SARS-CoV-2, por medio de las técnicas de aprendizaje profundo se logra con mayor rapidez y a menor costo.

La inteligencia de artificial, se podría comenzar por destacar algunas propiedades generales que presenta la inteligencia humana, como por ejemplo la habilidad de enfrentar nuevas situaciones, la habilidad de resolver problemas, de responder preguntas, elaborar planes, etc. Por tanto, la diferencia principal entre los ordenadores del futuro y los del pasado es que los primeros serán capaces de aprender y mejorar por sí mismos[19]. En este sentido, se podría considerar a la inteligencia artificial como un dialecto simbólico constituido por cadenas de caracteres que representan conceptos del mundo real[20]. Por otra parte, con la emergencia de la inteligencia

artificial y su uso en el campo de la radiología, en un esfuerzo por realizar un análisis cuantitativo de los estudios de imagen y de tal manera también un diagnóstico de mayor precisión, se han evaluado algoritmos que pueden proveer una estimación automática y objetiva de la severidad de la enfermedad facilitando la interpretación durante la pandemia[21].

Una red neuronal artificial es un modelo computacional inspirado en el sistema nervioso del ser humano[22]. La cual consiste en una capa de entrada, una o varias capas ocultas y una capa de salida[23]. Las redes neuronales se utilizan en su mayor dimensión en los últimos años. Sin embargo, los principales frameworks suelen ser complejos e impiden a muchos desarrolladores adentrarse en el aprendizaje profundo. En este sentido Keras es una API de redes neuronales escrita en lenguaje Python[24], Se trata de una biblioteca de código abierto que se ejecuta sobre frameworks como Theano y TensorFlow, diseñada para ser modular, rápida y fácil de usar, Keras fue creada por el ingeniero de Google, François Chollet. Ofrece una forma sencilla e intuitiva de crear modelos de Deep Learning[25]. En la actualidad, Keras es una de las API de redes neuronales más utilizadas para el desarrollo y las pruebas de redes neuronales[26]. Facilita enormemente la creación de capas para las redes neuronales o la configuración de arquitecturas complejas[27].

Los coronavirus son virus envueltos de ARN de sentido positivo no segmentados que pertenecen a la familia Coronaviridae y al orden Nido virales, y se distribuyen ampliamente en humanos y otros mamíferos, originando múltiples afecciones que van desde una gripe común hasta la muerte[28]. Los problemas de la enfermedad, provoca los principales síntomas son: fiebre, dolor de garganta, dolor muscular, tos seca y dificultad respiratoria aguda[10]. La rápida difusión del coronavirus y los graves efectos que provoca en seres humanos hacen imperioso un diagnóstico temprano de la enfermedad[5], el problema general es: ¿En qué ayuda el modelo de proceso de diagnóstico mediante la aplicación de técnica de Deep learning a partir de las imágenes de rayos x de los pulmones de los pacientes? y el estudio de investigación tiene como objetivo es determinar el modelo de proceso diagnóstico de COVID – 19 mediante la aplicación de la técnica de deep leaning a partir de imágenes de rayos X de los pulmones de los pacientes, 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. Estos modelos son VGG19, DenseNet169, ResNet101 y EfficientNetB0.

II. MÉTODO Y MATERIALES

La metodología utilizada en este estudio contiene 4 pasos, los cuales son: Carga de datos, Configuración, Entrenamiento y Predicción los cuales se detallan a continuación

A. Carga de datos

los experimentos se ejecutarán utilizando información recopilada de Kaggle conforme se muestra en la Fig. 1

El conjunto de datos está disponible en el siguiente enlace de Kaggle:

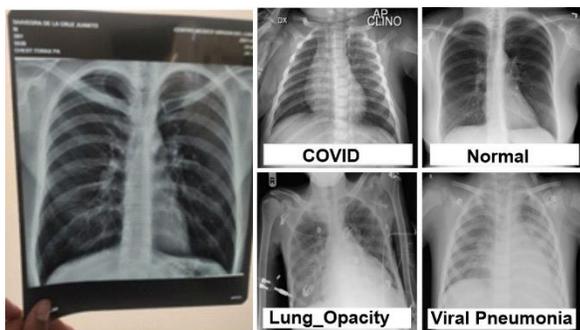


Fig. 1 Imágenes de rayos x del tórax de los pulmones. Fuente: Elaboración propia

B. Configuración

Se define el conjunto de datos o dataset para el entrenamiento, validación y prueba de la red neuronal convolucional. Para ello, se accede a la plataforma de Kaggle, que ofrece una amplia variedad de conjuntos de datos gratuitos para abordar problemas relacionados con el aprendizaje profundo.

El conjunto de datos seleccionado consiste en imágenes de radiografías de tórax que han sido clasificadas en radiografías con casos confirmados de COVID-19, así como radiografías de neumonía, opacidad pulmonar y normales. Obtenemos la mayor presión y exactitud con las imágenes de rayos x de torax. El preprocesamiento de las imágenes para un modelo de identificación de COVID-19 mediante técnicas de Deep Learning es crucial para asegurar que los datos sean aptos para el entrenamiento y la evaluación del modelo. Se ha considerado las imágenes de rayos X de tórax relacionadas con COVID-19. almacenadas en la plataforma de Kaggle imágenes de rayos X con manchas en los pulmones de: pacientes sanos, pacientes con neumonía y pacientes positivos con COVID-19. Sin embargo, algunas imágenes de los casos confirmados de COVID-19 no se obtuvieron con los parámetros mencionados anteriormente, por lo que no se tomó en cuenta. Además, se realiza la ecualización de histograma para uniformizar las características de las imágenes, con el objetivo de trabajar con imágenes que presenten similitudes en sus características (Fig. 2).

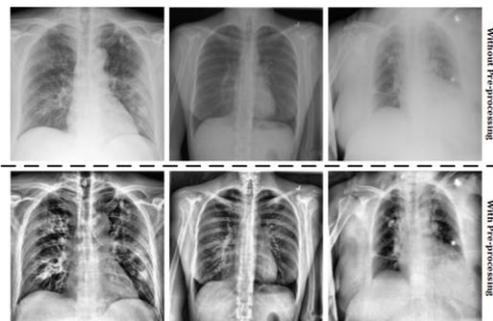


Fig. 2 Resultados del preprocesamiento

C. Entrenamiento

El entrenamiento de la red neuronal, se realizará con las radiografías clasificadas como casos positivos de COVID-19, neumonía, opacidad pulmonar y las radiografías normales, adquirida de la base de datos pertenece a la Sociedad Italiana de Radiología Medica e Intervencionista (SIRM) y al usuario

Prashant Patel, quien tiene su base de datos publicada en la plataforma Kaggle.

La estructura empleada en este estudio se fundamenta en la combinación de los modelos VGG-19, DenseNet169, ResNet101 y EfficientNetB0. Estos fueron entrenados mediante TensorFlow con Keras, seguido de una fase de preprocesamiento y una etapa final de clasificación, utilizando el parámetro de confianza obtenido durante el entrenamiento.

Entrenamiento: Empleando el entorno TensorFlow con Keras, se implementan cuatro arquitecturas (VGG-19, DenseNet169, ResNet101 y EfficientNetB0), las cuales se combinan a través de una capa de inferencia final para llevar a cabo el entrenamiento de un sistema clasificador con cuatro categorías (saludable, presencia de manchas en los pulmones, neumonía y COVID-19). El resultado final de esta etapa es el modelo de red neuronal convolucional.

D. Predicción

Después de obtener el modelo, se utiliza el conjunto de datos de prueba para evaluar la efectividad de la clasificación, obteniendo un factor de confianza. Este se utiliza para analizar el rendimiento de la CNN con el fin de evaluar su utilidad como herramienta de diagnóstico.

III. RESULTADOS

A. Analizar el algoritmo para el diagnóstico de COVID – 19 para mejorar el nivel de proceso de predicción a partir de imágenes de rayos X de los pulmones de los pacientes

Se utiliza un conjunto de datos que consta de imágenes de radiografías de tórax en este estudio, clasificadas en cuatro categorías: COVID, Lung Opacity, Normal y Viral Pneumonia. Cada categoría se divide en dos subcarpetas: "images", que alberga las imágenes de rayos X, y "mask", que contiene las máscaras pulmonares correspondientes. Las imágenes están en formato png y tienen un tamaño de 256 x 256 píxeles. Este conjunto de datos resulta crucial para el entrenamiento y la evaluación de modelos de aprendizaje profundo en la detección de COVID-19. se detallan las cuatro clases y la cantidad de imágenes asociadas (TABLA I).

TABLA I
CLASE DE IMÁGENES DE RAYOS X

Clase	Numero de Imágenes de rayos x de tórax	Porcentaje
Covid	36106	17 %
lung_Opacity	6012	28 %
Normal	10192	48 %
Viral Pneumonia	1345	6 %
Total	21165	100 %

Fuente: elaboración propia

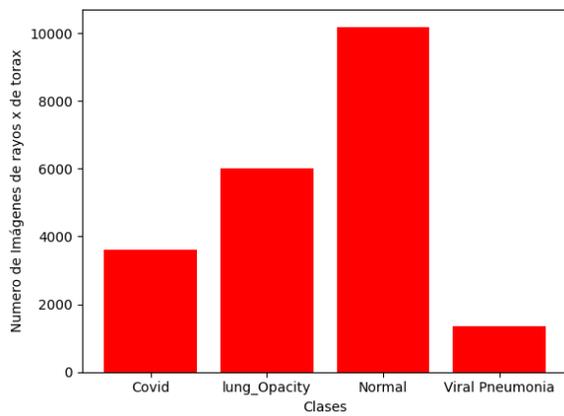


Fig. 1 Base de datos de imágenes de rayos x de tórax

En la (Fig. 3), se observa el conjunto de base de datos de las imágenes de rayos x de tórax y esta dividido en clases, para entrenar con los algoritmos de las redes neuronales convolucionales para el diagnóstico de COVID-19, demostrado una alta sensibilidad y especificidad. Esto significa que pueden identificar de manera precisa tanto los casos positivos como los negativos, lo que es esencial para evitar falsos negativos y falsos positivos. Además, en esta etapa temprana permite identificar los síntomas clínicos pueden ser leves o iniciales. Esto es crucial para tomar medidas preventivas (Fig. 4).

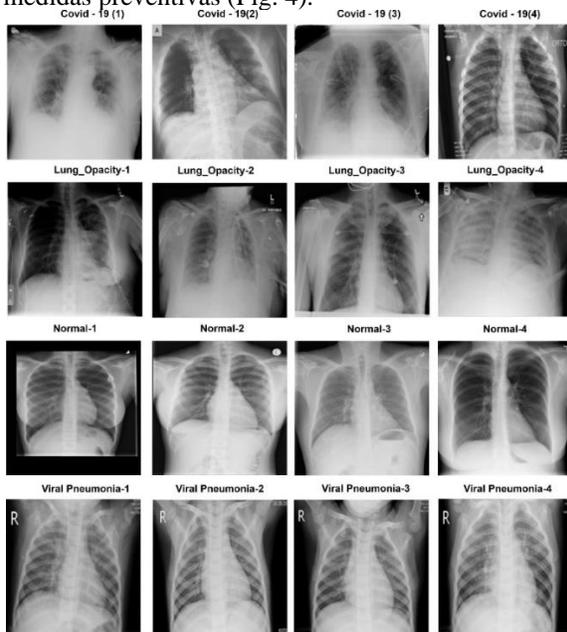


Fig. 2 imágenes de rayos x de tórax de los pulmones

B. *Evaluar el rendimiento del modelo en el conjunto de prueba utilizando métricas relevantes como presión, sensibilidad, especificidad*

Resultados del Modelo VGG19

Para conocer el desempeño del modelo VGG19, se utilizaron métricas de evaluación. Estas fueron precisión, recall y F1-score.

TABLA II
MÉTRICAS UTILIZADAS PARA VALORAR EL DESEMPEÑO DEL MODELO VGG19

Clases	Precisión	recall	f1-score	support
COVID	0.97	0.64	0.77	362
Lung Opacity	0.88	0.85	0.86	602
Normal	0.84	0.96	0.90	1019
Viral Pneumonia	0.90	0.92	0.91	134

Fuente: Elaboración propia

En la (TABLA II), se puede observar que el modelo VGG19 alcanzó una métrica de "recall" de 0.64 para la clasificación de casos de covid cuando fue entrenado.

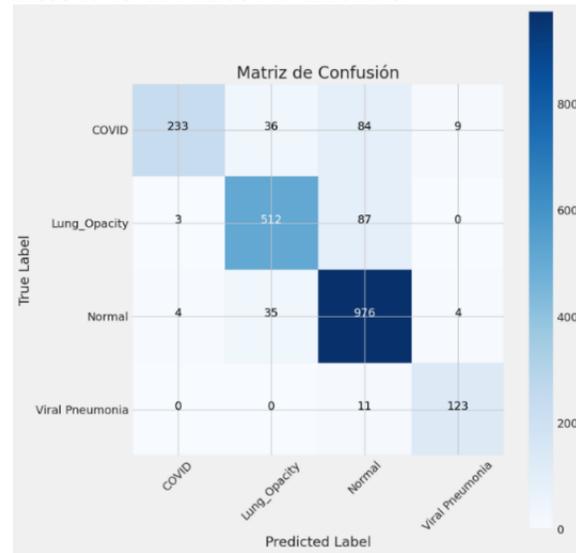


Fig. 3 Matriz de confusión de multiclase de VGG19.

En la (Fig. 5), se observa la matriz confusión de multiclase del modelo VGG19, se puede observar de las 262 imágenes de pruebas con covid 19, la red predijo 233 correctamente y 129 incorrectamente, de las 602 imágenes de Lung Opacity la red predijo 512 correctas y 90 incorrectamente, de las 1019 imágenes normal la red predijo 976 correctamente y 43 incorrectamente y de las 134 imágenes Viral Pneumonia la red predijo 123 correctas y 11 incorrectas.

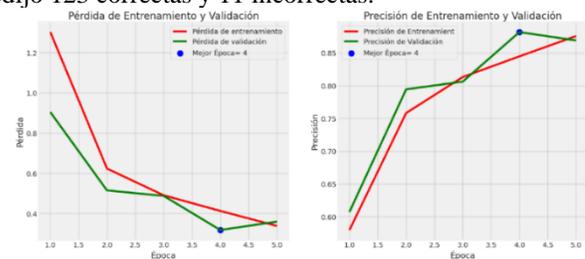


Fig. 4 a) Pérdida de entrenamiento y validación y b) precisión de entrenamiento y validación

En la (Fig. 6), se observa la pérdida de entrenamiento y la pérdida de validación disminuye conforme el número de épocas aumenta, y en relación a la precisión de entrenamiento y validación aumenta en relación a la época.

Resultados del Modelo DenseNet169

Para conocer el desempeño del modelo DenseNet169, se utilizaron métricas de evaluación. Estas fueron precisión, recall y F1-score. En la (TABLA III), muestra una comparación entre los valores de las métricas de medición obtenidas.

TABLA III
MÉTRICAS UTILIZADAS PARA VALORAR EL DESEMPEÑO DEL
MODELO DENSENET169

Clases	Precisión	recall	f1-score	support
COVID	0.89	0.99	0.94	362
Lung_Opacity	0.83	0.97	0.89	602
Normal	0.99	0.84	0.91	1019
Viral Pneumonia	0.96	1.00	0.98	134

Fuente: Elaboración propia.

En la (TABLA III), se puede observar que el modelo DenseNet169 alcanzó una métrica de "recall" de 0.99 para la clasificación de casos de COVID cuando fue entrenado

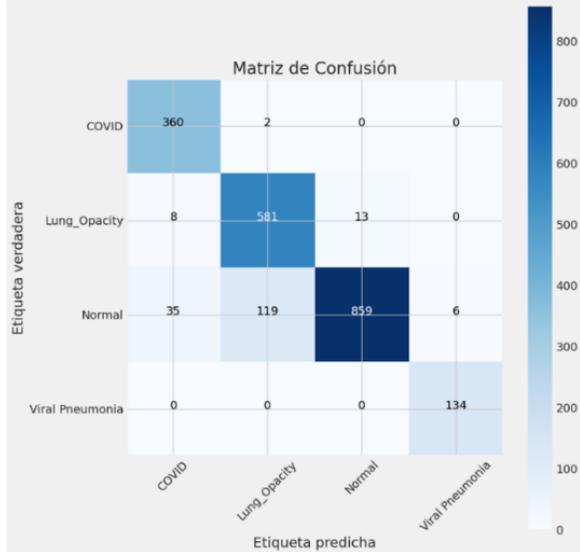


Fig. 5 Matriz de confusión de multiclase de DnseNet169

En la (Fig. 7), se observa la matriz de confusión de multiclase del modelo DenseNet169, se puede observar de las 362 imágenes de pruebas con covid 19, la red predijo 360 correctamente y 2 incorrectamente, de las 602 imágenes de Lung_Opacity la red predijo 581 correctas y 21 incorrectamente, de las 1019 imágenes normal la red predijo 859 correctamente y 160 incorrectamente y de las 134 imágenes Viral Pneumonia la red predijo 134 correctas y 0 incorrectas.

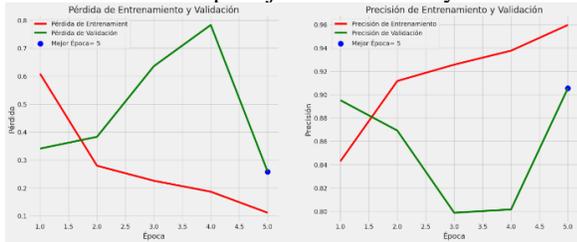


Fig. 6 Pérdida de entrenamiento y validación y b) precisión de entrenamiento y validación

En la (Fig. 8), se observa lo siguiente: a) la pérdida de entrenamiento y validación, en relación de la pérdida de entrenamiento disminuye conforme al número de épocas aumenta y la pérdida de validación aumenta en su máximo pico y disminuye conforme a número de épocas. Y b) precisión de validación; en relación de la precisión de entrenamiento aumenta conforme al número de épocas y la precisión de validación disminuye y aumenta conforme a número de épocas.
Resultados del Modelo ResNet101

Para conocer el desempeño del modelo ResNet101, se utilizaron métricas de evaluación. Estas fueron precisión, recall y F1-score. En la (TABLA IV), muestra una comparación entre los valores de las métricas de medición obtenidas

TABLA IV
MÉTRICAS UTILIZADAS PARA VALORAR EL DESEMPEÑO DEL
MODELO RESNET101

Clases	precision	recall	f1-score	support
COVID	0.98	0.96	0.97	362
Lung_Opacity	0.93	0.90	0.91	602
Normal	0.93	0.96	0.95	1019
Viral Pneumonia	1.00	0.95	0.97	134

Fuente: Elaboración propia

En la (TABLA IV), se puede observar que el modelo ResNet101 alcanzó una métrica de "recall" de 0.96 para la clasificación de casos de COVID cuando fue entrenado.

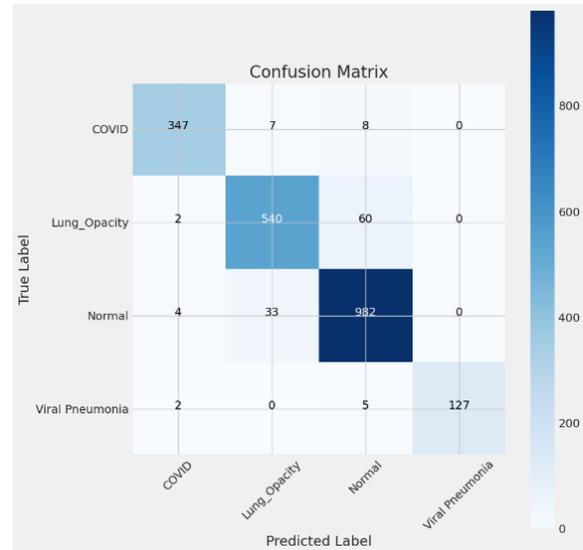


Fig. 7 Matriz de confusión de multiclase de ResNet101

En la (Fig. 9), se observa la confusión de matriz de multiclase del modelo ResNet101, se puede observar de las 362 imágenes de pruebas con covid 19, la red predijo 347 correctamente y 15 incorrectamente, de las 602 imágenes de Lung_Opacity la red predijo 540 correctas y 62 incorrectamente, de las 1019 imágenes normal la red predijo 982 correctamente y 37 incorrectamente y de las 134 imágenes Viral Pneumonia la red predijo 127 correctas y 7 incorrectas.

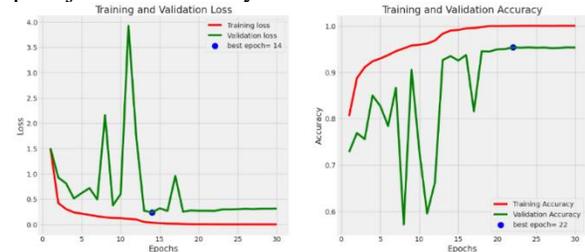


Fig. 8 Pérdida de entrenamiento y validación y b) precisión de entrenamiento y validación

En la (Fig. 10), se observa lo siguiente: a) la pérdida de entrenamiento y validación, en relación de la pérdida de entrenamiento disminuye conforme al número de épocas aumenta y la pérdida de validación aumenta en su máximo pico y disminuye conforme a número de épocas. Y b) precisión de validación; en relación de la precisión de entrenamiento

aumenta conforme al número de épocas y la precisión de validación aumenta conforme a número de épocas.

Resultados del modelo EfficientNetB0

Para conocer el desempeño del modelo EfficientNetB0, se utilizaron métricas de evaluación. Estas fueron precisión, recall y F1-score[29].

En la (TABLA V), muestra una comparación entre los valores de e las métricas de medición obtenidas

TABLA V
MÉTRICAS UTILIZADAS PARA VALORAR EL DESEMPEÑO DEL MODELO EFFICIENTNETB0

Clases	precision	recall	f1-score	support
COVID	0.99	0.99	0.99	362
Lung_Opacity				
Normal	0.99	1.00	1.00	1020
Viral Pneumonia	1.00	0.97	0.98	134

Fuente: elaboración propia

En la (TABLA V), se puede observar que el modelo EfficientNetB0 alcanzó una métrica de "recall" de 0.99 para la clasificación de casos de COVID cuando fue entrenado.



Fig. 9 Matriz de confusión de multiclase de EfficientNetB0

En la (Fig. 11), se observa la confusión de matriz de multiclase del modelo EfficientNetB0, se puede observar de las 362 imágenes de pruebas con covid 19, la red predijo 360 correctamente y 2 incorrectamente, de las 1020 imágenes normal la red predijo 1017 correctamente y 3 incorrectamente y de las 134 imágenes Viral Pneumonia la red predijo 130 correctas y 4 incorrectas.

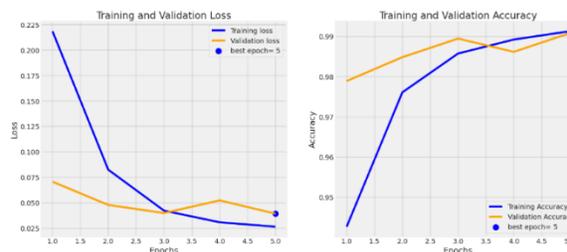


Fig. 10 Perdida de entrenamiento y validación y b) precisión de entrenamiento y validación

En la (Fig. 12), se observa como la perdida de entrenamiento y la perdida de validación disminuye conforme el número de épocas aumenta, y en relación a la precisión de entrenamiento y validación aumenta en relación a la época.

C. Comparar el rendimiento del modelo con otros métodos de diagnóstico para asegurar su eficacia y precisión

Se presenta la comparación entre los cuatro modelos de redes neuronales convolucionales basados en los resultados obtenidos por las métricas de medición y las matrices de confusión[30]. Estas tablas permiten evaluar el desempeño de los modelos para conocer cuál de los cuatro es apto. Son los algoritmos de las redes neuronales convolucionales VGG19, DenseNet169, ResNet101 y EfficientNetB0 para la identificación de COVID 19. Los resultados de la evaluación se muestran en la (TABLA VI).

TABLA VII
EVALUACIÓN COMPARATIVA DE LAS MATRICES DE RENDIMIENTO DE LOS MODELOS VGG19, DENSENET169, RESNET101 Y EFFICIENTNETB0

Modelo	Precision %	Recall %	F1 Score %
VGG19	99	99	99
DenseNet169	99	99	99
ResNet101	98	96	97
EfficientNetB0	99	99	99

Fuente: Elaboración propia.

La información de la (TABLA VI) indica que los modelos VGG19, DenseNet169 y EfficientNetB0 alcanzaron una tasa de acierto Precision y Recall del 99%, mientras que el modelo ResNet101 obtuvo una tasa de acierto menor, de 98% y 96% respectivamente.

IV. DISCUSIÓN

En la investigación de Márquez Diaz[14], para lograr el monitoreo, detección, diagnóstico y tratamiento de enfermedades asociados con el virus, utilizo el algoritmo de aprendizaje predictivo para minimizar los riesgos.

En la investigación de Catal-Reis[31], para la lograr la detección y el diagnostico tempranas de la infección de por COVID – 19 evitara la propagación. Los algoritmos se codificaron utilizando el lenguaje de programación Python y además los parámetros de desempeño que se utilizaron fueron exactitud, precisión, recuperación, puntaje-F1 y ROC-AUC.

En trabajo de investigación de Orozco[32], para lograr la detección temprana es fundamental para controlar la propagación y la mortalidad de los casos, por medio de las imágenes de rayos x, utiliza modelos de aprendizaje profundo como VGG19 y U-Net.

CONCLUSIÓN

Después de obtener los resultados y analizar e interpretar la información a la luz de las evidencias proporcionadas en este estudio, se puede concluir que:

- Se consiguió la identificación y clasificación del conjunto de datos utilizado para entrenar el modelo de redes neuronales convolucionales, con el objetivo de lograr una identificación más precisa en el diagnóstico de COVID-19 mediante el uso de imágenes de rayos X de tórax de pacientes. Que es difícil detectar para un observador humano, sin embargo, la detección temprana y rápida por medio de los algoritmos de redes neuronales convolucionales, permite identificar casos de enfermedad en etapas tempranas, incluso de que se manifieste síntomas clínicos significativos y permite tomar medidas preventivas.
- A lo largo de este estudio, se logró entrenar modelos destinados a la detección y predicción de COVID-19 empleando imágenes de radiografías de tórax. Los resultados obtenidos de los algoritmos VGG19, DenseNet169, ResNet101 y EfficientNetB0 están vinculados con redes neuronales convolucionales.
- La matriz de confusión, empleada en clasificación multiclase, es una herramienta para evaluar la eficacia de un modelo basado en aprendizaje automático.
- El resultado de mejor desempeño de los cuatro modelos evaluados son VGG19 DenseNet169 y EfficientNetB0, con 99% de precisión y sensibilidad en la implementación de los algoritmos.

REFERENCIAS

- [1] I. E. Mujica-Rodríguez, L. M. Toribio-Salazar, and D. F. Cándor-Cámara, "Inteligencia artificial como apoyo a intervenciones no farmacológicas para combatir la Covid-19," *Rev Peru Med Exp Salud Publica*, vol. 37, no. 3, pp. 582–584, 2020, [Online]. Available: <http://www.scielo.org.pe/pdf/rins/v37n3/1726-4642-rins-37-03-582.pdf>
- [2] I. Chérrez-Ojeda, L. Gochicoa-Rangel, A. Salles-Rojas, and H. Mautong, "Seguimiento de los pacientes después de neumonía por COVID-19. Secuelas pulmonares," *Rev Alerg Mex*, vol. 67, no. 4, 2021, doi: 10.29262/ram.v67i4.847.
- [3] A. Rosete, M. M. García Lorenzo, Y. Caballero, and R. Bello, "Un bosquejo de la Inteligencia Artificial frente a la covid-19 en el mundo," *Revista Cubana de Transformación Digital*, 2020, [Online]. Available: <http://portal.amelica.org/ameli/jatsRepo/389/3891734002/3891734002.pdf>
- [4] E. Martínez Chamorro, A. Díez Tascón, L. Ibáñez Sanz, S. Ossaba Vélez, and S. Borrueal Nacenta, "Diagnóstico radiológico del paciente con COVID-19," *Radiología*, vol. 63, no. 1, 2021, doi: 10.1016/j.rx.2020.11.001.
- [5] M. Xie and Q. Chen, "Insight into 2019 novel coronavirus — An updated interim review and lessons from SARS-CoV and MERS-CoV," *International Journal of Infectious Diseases*, vol. 94, pp. 119–124, 2020, doi: 10.1016/j.ijid.2020.03.071.
- [6] N. C. F. Javier Plaza Zamora, Guillermo Estrada Riobobos, Jesús C. Gómez Martínez, Vicente J. Baixauli Fernández, Ana Molinero Crespo, Eduardo Satué de Velasco, Luis Salar Ibáñez, *Sistemas menores y COVID 19*. Madrid, 2020. [Online]. Available: https://www.semg.es/images/2020/Coronavirus/20201015_sintomas_menores_covid_19.pdf
- [7] D. Wang *et al.*, "Clinical Characteristics of 138 Hospitalized Patients with 2019 Novel Coronavirus-Infected Pneumonia in Wuhan, China," *JAMA - Journal of the American Medical Association*, vol. 323, no. 11, pp. 1061–1069, 2020, doi: 10.1001/jama.2020.1585.
- [8] G. Bardález-Trigoso, J. P. Bazán-Arzapalo, J. Fabián, and P. Montenegro-Montori, "Detección del SARS-CoV-2 en radiografías de tórax por medio de descriptores intermedios y técnicas de machine learning," in *Actas del Congreso Internacional de Ingeniería de Sistemas 2020: Construyendo un mundo inteligente para la sostenibilidad*, 2021. doi: 10.26439/ciis2020.5505.
- [9] R. Sethi, M. Mehrotra, and D. Sethi, "Deep Learning based Diagnosis Recommendation for COVID-19 using Chest X-Rays Images," *Proceedings of the 2nd International Conference on Inventive Research in Computing Applications, ICIRCA 2020*, pp. 1–4, 2020, doi: 10.1109/ICIRCA48905.2020.9183278.
- [10] J. D. López-Cabrera, J. A. Portal-Díaz, R. Orozco-Morales, and M. Pérez-Díaz, "Revisión crítica sobre la identificación de covid-19 a partir de imágenes de rayos x de tórax usando técnicas de Inteligencia Artificial," *Revista Cubana de Transformación Digital*, vol. 1, pp. 67–99, 2020, [Online]. Available: <https://rctd.uic.cu/rctd/article/view/103>
- [11] J. Acevedo-flores, V. Pulido, and C. Neyra-rivera, "Tecnología para el control del COVID-19 : Una revisión del caso peruano Technology for the control of COVID-19 : A review of the Peruvian case," vol. 13, no. 4, pp. 473–475, 2020.
- [12] F. Juárez-Hernández *et al.*, "Hallazgos tomográficos en afectación pulmonar por COVID-19, experiencia inicial en el Instituto Nacional de Enfermedades Respiratorias Ismael Cosío Villegas, Ciudad de México," *NCT Neumología y Cirugía de Tórax*, vol. 79, no. 2, 2020, doi: 10.35366/94630.
- [13] J. F. Avila-Tomás, M. A. Mayer-Pujadas, and V. J. Quesada-Varela, "Artificial intelligence and its applications in medicine I: introductory background to AI and robotics," *Aten Primaria*, vol. 52, no. 10, pp. 778–784, Dec. 2020, doi: 10.1016/j.aprim.2020.04.013.
- [14] J. E. Márquez Díaz, "Inteligencia Artificial y Big Data como soluciones frente al COVID-19," *Rev Bioet Derecho*, no. 50, 2020, doi: 10.1344/rbd2020.50.31643.
- [15] M. D. Corbacho Abelaira, A. Ruano-Ravina, and A. Fernández-Villar, "Inteligencia artificial en radiología torácica. ¿Un reto en tiempos de la COVID-19?," vol.

- 57, pp. 15–16, 2021, doi: 10.1101/2020.03.23.20041608.10.
- [16] J. A. Gallego Mejía, “MLOps (Machine Learning Dev Ops),” *Revista Sistemas*, no. 165, 2022, doi: 10.29236/sistemas.n165a1.
- [17] A. Amanullah, Md. Z. Islam, Md. R. Haque, and Md. M. Islam, “Deep Learning Applications to Combat Novel Coronavirus (COVID-19) Pandemic,” *SN Computer Science (2020)*, 2020, [Online]. Available: <https://link.springer.com/article/10.1007/s42979-020-00383-w>
- [18] J. Diaz-Escobar *et al.*, “Deep-learning based detection of COVID-19 using lung ultrasound imagery,” *PLoS One*, 2021.
- [19] L. Rouhiainen, *Inteligencia artificial: 101 cosas que debes saber hoy sobre nuestro futuro*, Planeta, S.A. Barcelona: Alienta, 2018.
- [20] P. Ponce Cruz, *Inteligencia Artificial.*, Alfaomega Grupo. México, 2010.
- [21] N. Y. Muñoz-Jarillo, J. Arenal-Serna, R. Muñoz-Jarillo, and E. Camacho-Zarco, “Infección por SARS-CoV-2 (COVID-19) y sus hallazgos por imagen,” *Revista de la Facultad de Medicina*, vol. 63, no. 5, 2020, doi: 10.22201/fm.24484865e.2020.63.5.03.
- [22] C. E. Belman-López, “Detection of COVID-19 and other pneumonia cases using convolutional neural networks and X-ray images,” *Ingeniería e Investigación*, vol. 42, no. 1, 2022, doi: 10.15446/ing.investig.v42n1.90289.
- [23] L. Mera-Jiménez and J. F. Ochoa-Gómez, “Redes neuronales convolucionales para la clasificación de componentes independientes de rs-fMRI,” *Tecnológicas*, vol. 24, no. 50, 2021, doi: 10.22430/22565337.1626.
- [24] T. Koduru and E. Zhang, “Using Deep Learning in Lyme Disease Diagnosis,” *Journal of Student Research*, vol. 10, no. 4, 2021, doi: 10.47611/jsrshs.v10i4.2389.
- [25] F. Laporte, J. Dambre, and P. Bienstman, “Highly parallel simulation and optimization of photonic circuits in time and frequency domain based on the deep-learning framework PyTorch,” *Sci Rep*, vol. 9, no. 1, 2019, doi: 10.1038/s41598-019-42408-2.
- [26] A. Nandy and M. Biswas, *Reinforcement Learning: With Open AI, TensorFlow and Keras Using Python*. 2017. doi: 10.1007/978-1-4842-3285-9.
- [27] N. Ketkar and J. Moolayil, *Deep learning with python: Learn Best Practices of Deep Learning Models with PyTorch*. Apress Media LLC, 2021. doi: 10.1007/978-1-4842-5364-9.
- [28] M. Palacios-Cruz, E. Santos, M. A. Velázquez-Cervantes, and M. León-Juárez, “COVID-19. una emergencia de salud pública mundial,” *Rev Clin Esp*, vol. 221, no. 1, pp. 55–61, 2021, doi: 10.1016/j.rce.2020.03.001.
- [29] A. Karaci, “VGGCOV19-NET: automatic detection of COVID-19 cases from X-ray images using modified VGG19 CNN architecture and YOLO algorithm,” *Neural Comput Appl*, vol. 34, no. 10, 2022, doi: 10.1007/s00521-022-06918-x.
- [30] D. Lopez-Betancur, R. Bosco Duran, C. Guerrero-Mendez, R. Zambrano Rodríguez, and T. Saucedo Anaya, “Comparación de arquitecturas de redes neuronales convolucionales para el diagnóstico de COVID-19,” *Computación y Sistemas*, vol. 25, no. 3, 2021, doi: 10.13053/cys-25-3-3453.
- [31] H. Catal-Reis, “COVID-19 Diagnosis with Deep Learning,” vol. 2022, pp. 1–8, 2022.
- [32] S. Orozco-arias *et al.*, “Machine Learning with Applications COVID-19 detection in X-ray images using convolutional neural networks,” *Machine Learning with Applications*, vol. 6, no. August, p. 100138, 2021, doi: 10.1016/j.mlwa.2021.100138.