

# Detection of Covid-19 Through the Analysis of Radiographic Images of the Chest using Convolutional Neural Networks.

## Detección de Covid-19 Mediante el Análisis de Imágenes Radiográficas de Tórax usando Redes Neuronales Convolucionales.

Gladys Jacome-Morales, MSc<sup>1</sup>, Juan Cedeño-Rodríguez, MSc<sup>1</sup>, Darwin Patiño-Pérez, Ph.D<sup>1</sup>, Alex Collantes-Farah, MSIG<sup>1</sup>, Freddy Burgos-Robalino, MSc<sup>2</sup>, Víctor Pazmiño-Moran, MSc<sup>1</sup>, Miguel Molina-Calderón, MSIG<sup>1</sup>,

<sup>1</sup>Universidad de Guayaquil, Facultad de Ciencias Matemáticas y Física, Guayaquil, Ecuador, gladys.jacomem@ug.edu.ec, juan.cedenor@ug.edu.ec, darwin.patinop@ug.edu.ec, alex.collantesf@ug.edu.ec, victor.pazminom@ug.edu.ec, miguel.molinac@ug.edu.ec,

<sup>2</sup>Universidad de Guayaquil, Facultad de Ciencias Médicas, Guayaquil, Ecuador, freddy.burgosr@ug.edu.ec

**Abstract.** – There are different ways to detect Covid-19, which have emerged so far giving an effective response in detecting the disease, the PCR test is a reliable diagnostic method, which requires a well-equipped laboratory to obtain results, which can take hours or days. Another detection technique for this disease is by analyzing the chest image; This technique is used as a diagnostic tool in emergency areas in health centers, because it can reveal characteristics related to lung involvement. For this reason, it is important to develop an automatic detection system, as an alternative diagnosis option for Covid-19. Deep Learning techniques can help detect the SARS-CoV-2 virus by analyzing chest radiographic images.

Thanks to the high availability of the datasets available, and using convolutional neural networks, the analysis is carried out by classifying images. In this research, two CNN models were created whose outputs are normal or covid19, the same ones that were trained with two datasets from public research repositories. The performance of the models trained in Pytorch were compared with the models trained in Keras under similar conditions of parameters and hyperparameters, obtaining a higher performance with Pytorch however since the two types of models have learned adequately with an accuracy that is above the 90% recommended the use of both models.

**Keywords:** Covid-19, Chest X-rays, Deep learning, Convolutional Networks, Pytorch.

**Resumen.**– Existen diferentes formas para la detección de Covid-19, que han surgido hasta el momento dando una respuesta efectiva en la detección de la enfermedad, la prueba PCR es un método de diagnóstico confiable, que requiere de un laboratorio bien equipado para obtención de resultados, que puede demorar horas o días. Otra técnica de detección de esta enfermedad es mediante el análisis de la imagen del tórax; esta técnica se la utiliza como una herramienta de diagnóstico en las áreas de emergencias en los centros de salud, porque pueden revelar características relacionadas con la afectación en los pulmones. Por tal motivo, es importante desarrollar un sistema de detección automático, como una opción de diagnóstico alternativo del Covid-19.

*Las técnicas de Deep Learning pueden ayudar a detectar el virus SARS-CoV-2 mediante el análisis de imágenes radiográficas de tórax. Gracias a la alta disponibilidad del datasets con que se cuenta, y mediante el uso de redes neuronales convolucionales, el análisis se lo realiza mediante la clasificación de imágenes. En esta investigación se crearon dos modelos de CNN cuyas salidas son normal o covid19, los mismos que fueron entrenados con dos datasets provenientes de repositorios públicos de investigación. El rendimiento de los modelos entrenados en Pytorch fueron comparados con los modelos entrenados en Keras bajo similares condiciones de parámetros e hiperparámetros, obteniéndose un mayor rendimiento con Pytorch sin embargo puesto que los dos tipos de modelos han aprendido adecuadamente con una exactitud que está por encima del 90% se recomendó la utilización de ambos modelos.*

**Palabras Claves:** Covid-19, Radiografías de tórax, Deep learning, Redes Convolucionales, Pytorch.

### I. INTRODUCCION

La pandemia de COVID-19 marcó un antes y un después en la forma de convivir de todas las personas en el mundo, el virus SARS-CoV-2 que ocasiona un síndrome respiratorio agudo grave[1], fue descubierto por primera vez en diciembre del año 2019 en Wuhan-China, se propago rápidamente por todo el mundo y para octubre del 2020 llegó a Ecuador haciendo que el país ocupe el cuarto lugar en América y el noveno a nivel mundial, siendo uno de los países más afectados por el virus según datos de la Organización Mundial de la Salud[2].

Debido a que el virus afecta principalmente a los pulmones del paciente[3], las radiografías del tórax pueden ser de gran ayuda para un diagnóstico efectivo. Cualquier método que sea rápido, preciso, confiable y que reduzca la exposición del virus al personal médico sería de gran beneficio para el sistema médico[4]. El covid-19 es una enfermedad infecciosa causada por el virus SARS-CoV2, la enfermedad y el virus eran completamente desconocidos hasta que apareció un contagio masivo en la ciudad de Wuhan (China) y en cuestión de meses afectó a todo el

Digital Object Identifier (DOI):  
<http://dx.doi.org/10.18687/LEIRD2022.1.1.187>  
ISBN: 978-628-95207-3-6 ISSN: 2414-6390

mundo, tanto la situación económica y de salud se vieron afectadas gravemente, en aquel año varias investigaciones esperaban lograr encontrar una vacuna que ayude a disminuir la propagación y genere una inmunidad en todos los habitantes[5].

A nivel nacional se conoce que el primer caso de Covid-19 apareció por una persona que llegó al país desde España, lo que fue el detonante para el contagio inicial en el país. La pandemia en Ecuador se ha desarrollado de forma desigual en las provincias. Las dos ciudades más afectadas son Guayaquil y Quito debido a su numerosa población y además es en donde se encuentran los dos aeropuertos internacionales más grandes[6]. La nueva infección por coronavirus SARS-CoV-2 conocido como covid-19 ha tenido un impacto particular en los sistemas de salud en todo el mundo y en los trabajadores del sistema de salud, con impactos aún mayores en la capacitación de los profesionales de la salud. El virus procede de una fuente animal, se conoce que se transmite de persona a persona[7]. Aún no es claro que tan rápida puede ser esta transmisión, sin embargo, es de conocimiento común que la infección se produce cuando una persona enferma tose o estornuda y expulsa partículas del virus que entran en contacto con las mucosas (ojos, nariz y boca) de las personas con las que se tiene un contacto estrecho y su entorno[8]. En su fase aguda, el covid-19 grave se caracteriza por una enfermedad pulmonar aguda que puede manifestarse con neumonía y con síndrome respiratorio agudo[9].

La Inteligencia Artificial[10] ha cambiado el diario vivir de las personas, en el sentido de cómo la comunicación ha evolucionado en la interacción humana por medio de mecanismos que tienen una percepción propia[11] que aprenden rápidamente de datos clasificados[12], imágenes o con la propia interacción con los seres humanos. Una de las técnicas de la inteligencia artificial es el *deep learning* [13] la cual cuenta con una arquitectura computacional llamada redes neuronales convolucionales (CNN)[14] que en el pasado, demostraron ser bastante exitosas en la clasificación de imágenes médicas y que funciona aprendiendo características relevantes directamente desde las grandes bases de datos, de esta manera el aprendizaje profundo[15] es capaz de extraer características relacionadas con los resultados clínicos.

## II. MATERIALES Y METODOS

### A. Materiales

#### Imágenes de Tórax

Las técnicas de diagnóstico por imágenes del tórax[16] se han utilizado como una herramienta diagnóstica en el departamento de emergencias porque pueden revelar características relacionadas con la afectación en pulmones de covid-19. La imagen del tórax o radiografía (Rx) simple de tórax es una técnica sencilla, segura y de amplio uso en la valoración inicial de la covid-19. La afectación bilateral radiológica se ha identificado en pacientes críticos como un factor independiente de riesgo[17].




Fig. 1 Radiografía de hallazgos atípicos de neumonía covid-19.

Normalmente, las imágenes radiográficas[18] se utilizan como etapa inicial del diagnóstico para probar y evaluar la radiografía de un paciente para determinar si el paciente presenta síntomas de COVID-19[19] o se sospecha que tiene la enfermedad contagiosa. Según numerosos estudios, existe una fuerte correlación entre el desarrollo de la enfermedad y las anomalías pulmonares en las radiografías de tórax y los rayos X [20].

#### Dataset-1

En la Tabla I se refleja que el dataset-1 contiene 1143 imágenes de pulmones con covid y de pulmones sin covid-19 tiene 1348 imágenes, dando con un total de 2491 radiografías del tórax.[21]. Este dataset se lo obtuvo de [22] para una mejor comparación entre los modelos en las diferentes librerías de Pytorch y Keras.

TABLA I  
IMÁGENES DATASET-1

Tipo de Imágenes	Train	Val	Total
Covid-19	902	241	1143
Normal	910	438	1348
Total	1812	679	2491

#### Dataset-2

En la Tabla II se refleja que el dataset-2 cuenta con 1885 imágenes de pulmones con covid positivo y 1885 imágenes con pulmones sin covid, sumando en su totalidad 3770 imágenes radiográficas que se las obtuvieron de[23]. Aunque del repositorio anteriormente mencionado cuenta con 3616 imágenes de pulmones con covid y 10200 imágenes de pulmones normales; datos correspondientes al tercer trimestre del 2022, en la presente investigación se escogió de manera aleatoria las 3770 imágenes que formará los casos positivos y negativos del conjunto de imágenes. La finalidad de este dataset es comprobar la precisión de los modelos con un mayor número de imágenes para el entrenamiento.

TABLA II  
IMÁGENES DATASET-2

Tipo de Imágenes	Train	Val	Total
Covid-19	1450	435	1885
Normal	1450	435	1885
Total	2900	870	3770

## Dataset Test

En la Tabla III, se refleja que las imágenes del dataset para test o pruebas proviene de un banco de imágenes de un hospital público de la ciudad de Guayaquil, que proporcionaron 300 imágenes de radiografías de torax de pulmones sanos y 342 imágenes de pulmones infectados.

TABLA III  
IMÁGENES DATASET TEST

Tipo de Imágenes	Test	Total
Covid-19	342	342
Normal	300	300
Total	642	642

## B. Métodos

### Revisión de la Literatura

#### Modelos de Inteligencia Artificial

La inteligencia artificial[24], se considera como una serie de tecnologías utilizadas con el propósito de actuar como humanos, es decir, una serie de sistemas artificiales que permiten el desarrollo de tareas o actividades a través de máquinas. La IA abarca una gran variedad de subcampos[25], desde áreas de propósito general, como la percepción y el razonamiento lógico[26], hasta tareas específicas, como jugar al ajedrez, demostrar teoremas matemáticos, escribir poesía y en este caso diagnosticar enfermedades[27].

#### Tipos de Aprendizaje

Los tipos de aprendizaje se encuentran agrupados en tres categorías relacionadas con lo que necesitan los algoritmos para aprender, el *aprendizaje supervisado* [28] es uno de los más representativos y utilizados para la construcción de modelos predictivos. La máquina aprende de un conjunto de datos previamente etiquetados[29] por un experto o de forma automática basándose en los datos, es decir, para un conjunto de datos de entrada conocemos los datos de salida. Sin embargo, el *aprendizaje no supervisado* [30] que a diferencia del aprendizaje supervisado los algoritmos tienen como objetivo encontrar las regularidades o patrones en la entrada. Por ejemplo, en medicina se pueden proporcionar imágenes de tumores cerebrales[31] y el sistema se encarga de separar las imágenes en grupos de acuerdo con los patrones observados. Por otra parte, se tiene el *aprendizaje reforzado* [32] en donde, los algoritmos no tienen la necesidad de requerir grandes cantidades de datos para realizar su entrenamiento a diferencia de los otros dos tipos de aprendizaje, su forma de entrenar consiste en aprender a través de la prueba y el error aplicando la metodología de clasificación[33].

#### Red Neuronal Convolucional (CNN)

La red neuronal convolucional[34] Fig.2, es un tipo de red neuronal artificial que están dentro la categoría de *deep learning* o aprendizaje profundo[35], y que utiliza la convolución en lugar de la multiplicación general de matrices[36]. El objetivo de una CNN es aprender características en los datos a través de convoluciones. Se adaptan bien al reconocimiento de objetos con imágenes y compiten constantemente en la clasificación de imágenes.

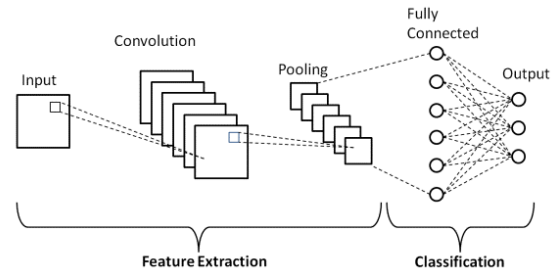


Fig. 2 Red Neuronal Convolucional

Además, este tipo de redes, pueden identificar rostros, personas, letreros de calles y muchos otros aspectos que contenga datos visuales. Las CNN[37] se superponen con el análisis de texto a través del reconocimiento óptico de caracteres, pero también son útiles cuando se analizan palabras como unidades textuales discretas. La convolución es ventajosa para muchos métodos conocidos de procesamiento de imágenes[38]. Existen otras categorías en las que se pueden dividir estas técnicas. "Multiplicar" dos conjuntos de números con anchos diferentes, pero con las mismas dimensiones es hacer una convolución[39].

#### Métricas de Evaluación.

La matriz de confusión[40] según Fig.3 es un mecanismo del cual se desprenden las métricas más intuitivas y sencillas que se utiliza para encontrar la precisión, exactitud, sensibilidad entre otras, es muy usada en problemas de clasificación donde la salida puede ser de dos o más tipos de clases[41], permite la visualización de errores y aciertos que tuvo el modelo en datos de validación o pruebas; contiene columnas y filas, donde las filas se refieren a las etiquetas reales del modelo y las columnas son las predicciones hechas por el modelo.

	Positive (1)	Negative (0)
Positive	TP	FP
Negative	FN	TN

Fig. 3. Matriz de Confusión

Accuracy.- La exactitud es la cantidad de predicciones positivas que fueron correctas[42].

$$\text{Accuracy} = \frac{(TN+TP)}{(FP+TP)+(TN+FN)} \quad (1)$$

Precision.- La precisión es el porcentaje de casos positivos detectados.

$$\text{Presicion} = \frac{TP}{(TP+FP)} \quad (2)$$

Recall.- La sensibilidad es una métrica muy utilizada en el campo de la medicina y es la capacidad de poder detectar correctamente en el caso de la salud, la enfermedad entre los enfermos.

$$\text{Recall} = \frac{TP}{(TP+FN)} \quad (3)$$

**Specificity.-** La especificidad es una métrica que se usa en el campo de la medicina, y es la capacidad de poder identificar los casos de pacientes sanos entre todos los sanos.

$$\text{Specificity} = \frac{TN}{(TN+FP)} \quad (4)$$

**ROC.-** Es la curva Característica Operativa del Receptor es el gráfico, que expone el rendimiento de un clasificador binario en función del umbral de corte, exponiendo la tasa de verdaderos positivos (TPR) contra la tasa de falsos positivos (FPR).

## Arquitecturas de CNN Implementadas

### Modelo Tipo-A




Fig. 4 CNN Tipo-A

La arquitectura según Fig.4 recibe como entrada la dimensión y canales de las imágenes de 3 x 224 x 224, debido a que las imágenes se transformaran a color se recibe con tres canales, en el modelo se eligió una arquitectura inicial de 5 capas convolucionales, 64 filtros en la primera capa, 128 filtros en la segunda capa, 256 filtros en la tercera capa, 512 filtros en la cuarta capa y 512 filtros en la quinta capa. En cada capa convolucional hay una función de activación ReLU y una función MaxPooling2. Las dimensiones del kernel, padding, stride de cada convolución serán las mismas por cada capa.

### Modelo Tipo-B




Fig.5 CNN Tipo-B

Por otra parte, la Fig. 5 está basada en [43] . Que recibe como entrada la dimensión y canales de las imágenes de 3 x 224 x 224, debido a que las imágenes se transformaran a color se recibe con tres canales, en el modelo tiene una arquitectura inicial de 4 capas convolucionales, 320 filtros en la primera capa, 228 filtros en la segunda capa, 128 filtros en la tercera capa y 128 filtros en la cuarta capa. En cada capa convolucional hay una función de activación ReLU y desde la segunda capa convolucional se aplica la función MaxPooling2. Las dimensiones del kernel, padding, stride de cada convolución serán las mismas por cada capa.

### Configuración de los Modelos

Los modelos fueron configurados según los hiperparámetros que se reflejan en la Tabla IV, para el esquema de optimización se utiliza Adam que es un esquema de optimización de mejora del descenso del gradiente[44] y basta con decir que es un optimizador más sofisticado en el que la tasa de aprendizaje se establece de forma adaptativa dejando que Pytorch haga los respectivos cálculos.

TABLA IV  
HYPERPARAMETROS

HyperParametros	Modelo-A	Modelo-B
Epochs	200	100
Batch Size	32	16
Tasa de Aprendizaje	0.0001	0.0001
Optimizador	Adam	Adam
Función de pérdida	CrossEntropyLoss	CrossEntropyLoss

Algo importante a recalcar es que la tasa de aprendizaje será disminuida a 0.00001 al entrenarse con el dataset-2 en los dos modelos.

## III.RESULTADO Y DISCUSIÓN

Para un mayor análisis de realizo la creación de gráficos a partir de los datos históricos recopilados, las métricas de los gráficos de perdida y precisión, nos ayudan a entender el comportamiento que tuvieron las redes neuronales durante el entrenamiento, un gráfico de la precisión es el encargado de analizar los conjuntos de datos y validación a través las épocas de formación, mientras que el gráfico de pérdidas tiene como función enfocarse en los conjuntos de datos de formación y validación sobre las épocas de formación.

### Modelo A (dataset-1)




Fig.6. Modelo A con el dataset-1 en pytorch



En Fig.6 la precisión , se logra visualizar que durante el entrenamiento de las CNN con 200 épocas el modelo A con la librería de pytorch, desde la época de partida , se tiene una precisión en los sets de entrenamiento del 0.99 con variaciones hasta el epoch 25 , pero comenzando de este epoch los datos se mantienen constantes con una precisión del 100 hasta la última iteración, mientras que en el set de validación en las primeras iteraciones, la precisión va en incremento desde 0.96 hasta un poco más de 0.99 donde este último valor se mantiene, excepto en la iteración 25 a que se logra visualizar unas bajadas, pero después de eso el modelo se queda constante hasta la última iteración.




Fig. 7. Modelo A con el dataset-1 en keras

En Fig. 7 la precisión obtenida usando la librería de keras con un dataset de 2491 En los sets de entrenamiento se muestra una línea constante desde la primera iteración o epoch hasta la alcanzar una precisión del 0,975 aumentando con el paso de los epoch teniendo su máxima precisión en el epoch 175 alcanzado así una precisión casi perfecta , para los sets de validación su comportamiento es discontinuo ya que presenta algunos cambios , pero el más relevante se da en el epoch 75 con una bajada en su precisión.

### Modelo B (dataset-1)




Fig. 8. Modelo B con el dataset-1 en pytorch

En Fig. 8 la precisión elaborada en pytorch con el modelo B del dataset-1 entrenada con 100 iteraciones. En los sets de entrenamiento se muestra una línea constante desde la iteración o epoch inicial obteniendo una precisión intermedia entre 0.96 a 0.98 aumentando con el paso de los epoch alcanzado así una precisión casi perfecta, para los sets de validación su comportamiento es discontinuo ya que presenta algunos picos de subidas y bajadas, pero se obtiene una precisión entre 0.98 a 1.00.




Fig. 9. Precisión del modelo B con el dataset-1 en keras

En Fig. 9 se logra visualizar que durante el entrenamiento del modelo B con el primer dataset en la librería keras los dos sets puestos a prueba actúan de forma similar ya que presenta algunas variaciones que va de forma creciente en el transcurso cada iteración, alcanzó así su punto máximo entre el intervalo de iteraciones de 80 a 100.

### Modelo A (dataset-2)




Fig. 10. Modelo A con el dataset-2 en pytorch

En Fig. 10 la gráfica de precisión presentado del modelo A con un dataset de 3770 en pytorch se observa en los dos sets dos sets una curva que va de manera creciente, para el set de entrenamiento se aprecia unos pequeños picos de subida y bajada en las primeras 200 iteraciones luego de eso se podría decir que el modelo que se comporta de forma constante ya que no se presenta muchos cambios hasta la última iteración logrando así alcanzar una precisión perfecta es decir del 100%, el set de validación tiene un comportamiento similar al set de entrenamiento pero este alcanza una precisión no menor al 0.90 en sus primeras 25 iteraciones.




Fig. 11. Modelo A con el dataset-2 en keras

En Fig. 11 la gráfica de precisión y pérdida del modelo A con el segundo data set en pytorch se observa que ambos sets inician con una precisión menor a 0.65 en donde la a través de las iteraciones el set de entrenamiento tiene una curva creciente hasta lograr un 100% en la última iteración, no se puede decir lo mismo del set de validación a pesar de que su curva si es creciente su comportamiento a medida que transcurre cada iteración es discontinuo.

### Modelo B (dataset-2)




Fig. 12. Modelo B con el dataset-2 en pytorch

En Fig.12 la gráfica de precisión y pérdida del modelo B con el segundo dataset en pytorch se visualiza que durante el entrenamiento de la CNN los sets de datos obtienen una curva que se interrelaciona a medida de cada iteración, pero la curva del set de entrenamiento comienza a subir de manera notable logrando una precisión mayor al 0.9 en su última iteración.




Fig. 13. Modelo B con el dataset-2 en keras

En Fig.13 la gráfica de la precisión y pérdida del modelo B con el segundo data set en keras se visualiza que durante el entrenamiento de la CNN los dos sets de datos tienen una curva de forma creciente a través de cada iteración obteniendo así una precisión mayor a 0.80, alcanzó su máximo punto de precisión llegando a la última iteración.

Ahora con los resultados de la precisión y pérdida del entrenamiento, es en donde Pytorch tiene una mejora en todos los modelos con los diferentes datasets que se probó en la investigación. En la Tabla V se muestra los resultados de las métricas de evaluación de Pytorch.

Modelos CNN	Precisión	Sensibilidad	F1 Score
Modelo A (dataset-1)	0.994	0.998	0.995
Modelo B (dataset-1)	0.996	0.994	0.994
Modelo A (dataset-2)	0.919	0.993	0.954
Modelo B (dataset-2)	0.917	0.96	0.938

De los modelos ejecutados en Pytorch de las diferentes pruebas en los distintos datasets, el que mejor resultado mostro fue del modelo A con el dataset-1 con un F1 Score de 0.995 y con no tanta diferencia le sigue el modelo B con el dataset-1, también se muestra que los resultados con el dataset-2 tienen un F1 Score inferior a los del otro dataset en comparación.

En la Tabla 5 se muestran los resultados obtenidos de los modelos entrenados en la librería de Keras.

Modelos CNN	Precisión	Sensibilidad	F1 Score
Modelo A (dataset-1)	0.9861	0.9907	0.988
Modelo B (dataset-1)	0.982	0.997	0.989
Modelo A (dataset-2)	0.952	0.876	0.912
Modelo B (dataset-2)	0.9832	0.96	0.899

En la Tabla VI se muestra el mismo patrón que los modelos ejecutados en Pytorch en donde los resultados con el dataset 1 son superiores a los resultados obtenidos con el dataset-2, la única diferencia es que en Keras el modelo B con el dataset-1 es la que obtiene un F1 Score de 0.989 superior a los demás y con diferencia de una centésima le sigue el modelo A con el dataset con un F1 Score de 0.988. Comparando los mejores resultados de cada modelo, se muestra que el modelo A con el dataset 1 ejecutado en Pytorch es que el mejor resultado obtuvo en el entrenamiento con una CNN, en todos los modelos Pytorch fue superior a Keras.

En cuanto a tiempos en el modelo A se muestra una diferencia a favor de Pytorch ya que en el con el dataset-1 se demora un 19.34% menos tiempo en entrenar en comparación a Keras y con el dataset-2 se demora un 19.75% menos tiempo en entrenar el modelo a diferencia de Keras. Con respecto al Modelo B, es en donde Pytorch demora más tiempo ya que con el dataset 1 se demora un 36,1% más de lo que le toma a Keras entrenar el modelo y con el dataset-2 se demora un 35.9% en comparación con los mismos parámetros en el modelo en Pytorch. Cabe recalcar que el modelo A tiene en total 110,773,329 de parámetros para entrenamiento, así como el modelo B tiene 32,712,737 de parámetros para el mismo fin. Estos tiempos de ejecución del entrenamiento de un modelo depende de la capacidad y potencia del GPU, mientras más potente sea la tarjeta de video más rápido el entrenamiento del modelo terminara independientemente de la librería en la que se esté ejecutando.

#### IV. CONCLUSIONES

En la Tabla. VII se reflejan los tiempos de ejecución de cada uno de los modelos implementados en las librerías de keras y pytorch, se obtuvieron tiempos de ejecución variantes que dependen de los parámetros con que se configuraron los modelos; se observó que el incremento en la precisión a la hora de predecir favoreció a los modelos implementados en pytorch frente a los modelos basados en keras.

TABLA VII  
TIEMPO DE EJECUCIÓN DE ENTRENAMIENTOS

Modelos CNN	Pytorch	Keras	Diferencias de Tiempo	
Modelo A (dataset-1)	105m 55s	131m 19s	-26m 36s	+19,34%
Modelo B (dataset-1)	157m 59s	116m 08s	-123m 00s	-36,1%
Modelo A (dataset-2)	121m 46s	152m 05s	31m 41s	-19,75%
Modelo B (dataset-2)	314m 58s	231m 39s	82m 19s	+35,9%

Los modelos implementados en pytorch ofrecieron un mejor rendimiento que los modelos implementados en keras, para el comparativo los modelos se ejecutaron en iguales condiciones, por los que es evidente que el desarrollo en pytorch resultó más eficiente que keras.

Se comprobó que la ejecución de los dos modelos en GPU ofreció menor tiempo de ejecución que en CPU y dado que las precisiones alcanzadas en ambos escenarios son adecuadas y aceptables por encima del 90% de exactitud, se pueden estimar como factible la aplicación de ambos modelos ya que el estándar base promedio de recomendación de efectividad está entre el 75% y 80%.

Puesto que para la detección de Covid19, el análisis de imágenes es una técnica muy empleada en las áreas de emergencias de los centros de salud, que requieren de suficientes especialistas que revisen las imágenes de forma manual y por observación para la emisión de un diagnóstico; la implementación de estos modelos de redes neuronales convolucionales, que han aprendido a detectar la presencia de Covid19 mediante el análisis de imágenes con una efectividad muy elevada, se recomienda ponerlos en funcionamiento a ambos modelos en los centros de salud como una ayuda para la detección rápida y confiable de la enfermedad.

Solo en el caso excepcional que los equipos de computación en las áreas de emergencia de los centros de salud tengan un buen performance y cuenten con GPU de última generación se recomendaría que se use el modelo basado en pytorch para aprovechar la versatilidad del recurso de hardware.

#### REFERENCIAS

- [1] D. Tworowski *et al.*, "COVID19 Drug Repository: Text-mining the literature in search of putative COVID19 therapeutics," *Nucleic Acids Res.*, vol. 49, no. D1, 2021.
- [2] M. A. Shereen, S. Khan, A. Kazmi, N. Bashir, and R. Siddique, "COVID-19 infection: Origin, transmission, and characteristics of human coronaviruses," *Journal of Advanced Research*, vol. 24, 2020.
- [3] J. R. Vielma Guevara, J. del C. Villarreal Andrade, and L. V. Gutiérrez Peña, "Pandemia por el SARS-CoV-2: aspectos biológicos, epidemiológicos y clínicos," *Observador del Conocimiento. Revista Especializada de Gestión Social del Conocimiento*, vol. 5, no. 3, 2020.
- [4] S. Akter, F. M. J. M. Shamrat, S. Chakraborty, A. Karim, and S. Azam, "COVID-19 Detection Using Deep Learning Algorithm on Chest X-ray Images," *Biology (Basel)*, vol. 10, no. 11, p. 1174, Nov. 2021.
- [5] J. S. Cobb and M. A. Seale, "Examining the effect of social distancing on the compound growth rate of COVID-19 at the county level (United States) using statistical analyses and a random forest machine learning model," *Public Health*, vol. 185, p. 27, Aug. 2020.
- [6] "MTT2-NACIONAL."
- [7] A. M. R. Pérez, T. J. J. Gómez, and G. R. A. Dieguez, "Características clínico-epidemiológicas de la COVID-19," *Rev. Habanera Ciencias Médicas* 19(2)e\_3254, pp. 1–15, 2020.
- [8] W. Wang *et al.*, "Detection of SARS-CoV-2 in Different Types of Clinical Specimens," *JAMA - J. Am. Med. Assoc.*, vol. 323, no. 18, pp. 1843–1844, May 2020.
- [9] R. Reyna, F. Gutiérrez, and C. Previgliano, "Neumonía por COVID19: Valoración por imagen, lo básico [COVID19 pneumonia: Imaging evaluation, the basics]," *Rev. Médica Panamá - ISSN* 2412-642X, vol. 42, no. 02, 2020.
- [10] M. Álvarez Vega, L. M. Quirós Mora, and M. V. Cortés Badilla, "Inteligencia artificial y aprendizaje automático en medicina," *Rev. Medica Sinerg.*, vol. 5, no. 8, 2020.
- [11] N. Becerra Yoma Prof. and L. Mendoza Inzunza Dra., "Inteligencia artificial aplicada a la medicina respiratoria," *Rev. Chil. enfermedades Respir.*, vol. 37, no. 4, 2021.
- [12] V. Roman, "Aprendizaje No Supervisado en Machine Learning: Agrupación | by Victor Roman | Ciencia y Datos | Medium," *Medium*, 2019.
- [13] J. Ma, Y. Song, X. Tian, Y. Hua, R. Zhang, and J. Wu, "Survey on deep learning for pulmonary medical imaging," *Frontiers of Medicine*, vol. 14, no. 4, 2020.
- [14] H. Alhichri, "CNN Ensemble Approach to Detect COVID-19 from Computed Tomography Chest Images," *Comput. Mater. Contin.*, vol. 67, no. 3, 2021.
- [15] J. Díaz-Ramírez, "Aprendizaje Automático y Aprendizaje Profundo," *Ingeniare. Rev. Chil. Ing.*, vol. 29, no. 2, 2021.
- [16] J. C. de J. Montero Rodríguez, R. Roshan Biswal, and E. S. de la Cruz, "Algoritmos de aprendizaje automático de vanguardia para el diagnóstico de enfermedades," *Res. Comput. Sci.*, vol. 148, no. 7, 2019.
- [17] J. Aldrete *et al.*, "Mortalidad por enfermedad renal crónica y su relación con la diabetes en México," *Med. Interna México*, vol. 34, no. 4, 2018.
- [18] S. Lucía Mayanga-Sausa *et al.*, "Utilidad de la radiografía de tórax en el contexto de la pandemia

por SARS-CoV-2,” *Rev. la Fac. Med. Humana*, vol. 20, no. 4, 2020.

- [19] A. Ramírez-Gutiérrez de Velasco, A. C. Vadillo-Santos, P. Pérez-Ladrón de Guevara, and O. Quiroz-Castro, “COVID-19: historia actual de una pandemia y sus hallazgos clínico-radiológicos,” *Rev. An. Radiol. México*, vol. 19, no. 2, 2020.
- [20] X. Li, C. Li, and D. Zhu, “COVID-MobileXpert: On-Device COVID-19 Patient Triage and Follow-up using Chest X-rays,” in *Proceedings - 2020 IEEE International Conference on Bioinformatics and Biomedicine, BIBM 2020*, 2020.
- [21] Y. Gan, H. Zhu, W. Guo, G. Xu, and G. Zou, “Deep semi-supervised learning with contrastive learning and partial label propagation for image data,” *Knowledge-Based Syst.*, vol. 245, 2022.
- [22] D. P. Perez, R. S. Bustillos, M. Botto-Tobar, and C. M. Mora, “X-Ray Images Analysis by Medium Artificial Neural Network,” *Ecuadorian Sci. J.*, vol. 5, no. 1, pp. 55–60, Mar. 2021.
- [23] M. A. Markom *et al.*, “A Review: Deep Learning Classification Performance of Normal and COVID-19 Chest X-ray Images,” in *Journal of Physics: Conference Series*, 2021, vol. 2071, no. 1.
- [24] F. Tablado, “Inteligencia artificial: Definición, tipos y aplicaciones | Grupo Atico34.” [Online]. Available: <https://protecciondatos-ldp.com/empresas/inteligencia-artificial/>. [Accessed: 06-Jul-2021].
- [25] V. Arias *et al.*, “Una introducción a las aplicaciones de la inteligencia artificial en Medicina: Aspectos históricos,” *Rev. Latinoam. Hipertens.*, vol. 14, no. 5, 2019.
- [26] J. P. Cárdenas-Ruperti, F. S. Durán-Pérez, and L. A. Padilla-Álvarez, “Un enfoque de Machine Learning y razonamiento probabi-lístico en el pronóstico de factores de riesgo de la diabetes,” *Ecuadorian Sci. J.*, vol. 4, no. 1, 2020.
- [27] K. A. Heredia-Menor and W. Mamani-Ticona, “Comparación de técnicas basadas en visión computacional y machine learning para la detección temprana de anemia a partir del análisis de uñas,” in *Actas del Congreso Internacional de Ingeniería de Sistemas 2020: Construyendo un mundo inteligente para la sostenibilidad*, 2021.
- [28] A. R. Valdez Alvarado, “Machine Learning para Todos,” *Reseachgate*, no. January 2019, 2019.
- [29] C. G. Xanthis, D. Filos, K. Haris, and A. H. Aletras, “Simulator-generated training datasets as an alternative to using patient data for machine learning: An example in myocardial segmentation with MRI,” *Comput. Methods Programs Biomed.*, vol. 198, 2021.
- [30] I. C. Pérez Verona and L. A. García, “Una revisión sobre aprendizaje no supervisado de métricas de distancia A brief review on unsupervised metric learning,” *Rev. Cuba. Ciencias Informáticas*, vol. x, no. x, 2010.
- [31] M. Aedo Lopez and E. G. Castro Gutierrez, “Implementación de un Modelo basado en técnicas de Deep Learning aplicado a la Visión Computacional en la Clasificación de Imágenes de Rayos X, para el soporte del diagnóstico de lesiones traumatológicas de la Estructura Pélvica,” 2019.
- [32] Mauricio Arango, “Introducción al Aprendizaje por Refuerzo,” *Oracle A-Team*, no. August, 2019.
- [33] J. Zamorano Ruiz, “Comparación y análisis de métodos de clasificación con las bibliotecas scikit-learn y TensorFlow en Python,” *J. Chem. Inf. Model.*, vol. 53, no. 9, 2019.
- [34] I. D. Apostolopoulos, S. I. Aznaouridis, and M. A. Tzani, “Extracting Possibly Representative COVID-19 Biomarkers from X-ray Images with Deep Learning Approach and Image Data Related to Pulmonary Diseases,” *J. Med. Biol. Eng.*, vol. 40, no. 3, 2020.
- [35] “Deep Autoencoder-Based Image Compression using Multi-Layer Perceptrons,” *Int. J. Soft Comput. Eng.*, vol. 9, no. 6, 2020.
- [36] F. López Saca, A. Ferreyra Ramírez, C. Avilés Cruz, and J. Villegas Cortéz, “Red neuronal convolucional con extracción de características multi-columna para clasificación de imágenes,” *Res. Comput. Sci.*, vol. 148, no. 7, 2019.
- [37] L. Alzubaidi *et al.*, “Review of deep learning: concepts, CNN architectures, challenges, applications, future directions,” *J. Big Data*, vol. 8, no. 1, 2021.
- [38] D. C. Ramírez González, G. Pulido Sarmiento, B. Gerardino Arévalo, J. M. Cruz Romero, E. Estupiñán Escalante, and S. Cancino Suárez, “Adquisición y Reconocimiento de Imágenes por Medio de Técnicas de Visión e Inteligencia Artificial,” *ITECKNE*, vol. 6, no. 1, Jun. 2009.
- [39] R. Jiménez Moreno, O. Avilés, and D. M. Ovalle, “Red neuronal convolucional para discriminar herramientas en robótica asistencial,” *Visión electrónica*, vol. 12, no. 2, 2018.
- [40] P. de los Santos, “Machine Learning a tu alcance: La matriz de confusión,” *Think Big Empresas*, 2018. .
- [41] C. Ferrin-Bolanos, L. Valero-Echeverri, H. Loaiza-Correa, J. Mosquera-Delacruz, and P. Velez-Angel, “Introducción a la Clasificación de Neuroseñales utilizando Técnicas Clásicas y Modernas de Machine Learning en Google Colaboratory,” in *2021 22nd Symposium on Image, Signal Processing and Artificial Vision, STSIVA 2021 - Conference Proceedings*, 2021.
- [42] R. T. Valencia Portillo, B. Amorín Uscata, F. A. Gonzales-Zubiate, K. Juscamaita Medina, O. R. Sevillano, and E. M. Ramos-Sanchez, “Pruebas rápidas para COVID-19, la mejor alternativa para Ecuador,” *Bionatura*, vol. 5, no. 3, 2020.
- [43] M. R. Islam and M. Nahiduzzaman, “Complex features extraction with deep learning model for the detection of COVID19 from CT scan images using ensemble based machine learning approach,” *Expert Syst. Appl.*, vol. 195, 2022.
- [44] A. V. Konstantinov and L. V. Utkin, “Interpretable machine learning with an ensemble of gradient boosting machines,” *Knowledge-Based Syst.*, vol. 222, 2021.