

Deep Learning para la Detección de Covid19 mediante Análisis de Imágenes de Pruebas Rápidas.

Deep Learning for the Detection of Covid-19 Through Test Image Analysis Fast.

Darwin Patiño-Pérez, Ph.D¹, Gladys Jacome-Morales, MSc¹, Juan Cedeño-Rodríguez, MSc¹, Miguel Botto-Tobar, MSc¹, Dalva Icaza-Rivera, MAE¹, Freddy Burgos-Robalino, MDGPT², Liliana Sarmiento-Barreiro, MSIG²,

¹Universidad de Guayaquil, Facultad de Ciencias Matemáticas y Física, Ecuador, darwin.patinop@ug.edu.ec, gladys.jacmem@ug.edu.ec, juan.cedonor@ug.edu.ec, miguel.bottot@ug.edu.ec,

²Universidad Estatal de Milagro, Facultad de Administración, Milagro, Ecuador, dicazar@unemi.edu.ec,

³Universidad de Guayaquil, Facultad de Ciencias Médicas, Ecuador, freddy.burgosr@ug.edu.ec, liliana.sarmientob@ug.edu.ec

Resumen.— En la actualidad, las pruebas rápidas para la detección de COVID-19 son un mecanismo muy útil y usado como una opción para la detección rápida de una infección en curso por COVID 19, puesto que, otros métodos de diagnóstico son más complejos, y demandan de análisis, tiempo y recursos. En el área de la salud se ha optado por utilizar herramientas de inteligencia artificial que ayuden a detectar pacientes sintomáticos y asintomáticos, para evitar una futura propagación. Las redes neuronales convolucionales (CNN), son las más convenientes dado que poseen la capacidad de aprender por sí mismas a identificar características dentro de imágenes. No obstante, es necesario el entrenamiento de una red neuronal convolucional mediante el uso de un dataset de imágenes. Puesto que se cuenta con un dataset reducido de apenas dos mil imágenes, se empleó una técnica para aleatorizar y re-escalar las imágenes con el fin de aumentar en gran medida el dataset y utilizarlo como datos de entrenamiento en una CNN, logrando potenciar su rendimiento. Al obtener las imágenes generadas, se creó un modelo de CNN, el cual se llevó a cabo en el entorno Google Colab, usando el lenguaje de programación python y librerías de machine learning como Keras, Tensorflow y OpenCV, mediante aprendizaje automático el modelo aprendió a predecir mediante clasificación llegando a obtenerse una exactitud del 97% en predicción con una pérdida del 6.69% y sin haber caído en sobre entrenamiento se recomendó su uso puesto que su nivel de generalización alcanzó el 84%.

Palabras Claves: Covid-19, Inteligencia Artificial, Deep Learning, Redes Neuronales Convolucionales, Python.

Abstract. – Currently, rapid tests for the detection of COVID-19 are a very useful mechanism and used as an option for the rapid detection of an ongoing infection by COVID 19, since other diagnostic methods are more complex, and require analysis, time and resources. In the health area, it has been decided to use artificial intelligence tools that help detect symptomatic and asymptomatic patients, to prevent future spread. Convolutional neural networks (CNN) are the most convenient since they can learn by themselves to identify features within images. However, it is necessary to train a convolutional neural network using image datasets.

Since there is a small dataset of just two thousand images, a technique was used to randomize and rescale the images to greatly increase the dataset and use it as training data in a CNN, thus enhancing its performance. By obtaining the generated images, a CNN model was created, which was carried out in the Google Colab environment, using the python programming language and machine learning libraries such as Keras, Tensorflow and OpenCV, through automatic learning the model learned to predict by classification, obtaining an accuracy of 97% in prediction with a loss of 6.69% and without having fallen into overtraining, its use was recommended since its level of generalization reached 84%.

Keywords: Covid-19, Artificial Intelligence, Deep Learning, Convolutional Neural Networks, Python.

I. INTRODUCCION

El SARS-CoV-2 es un virus altamente contagioso que causa la enfermedad COVID-19 según la Fig.1. Se identificó por primera vez en Wuhan, China, en diciembre de 2019 y se propagó rápidamente a nivel mundial, lo que resultó en una pandemia[1]. Esta enfermedad infecciosa, causó un colapso en todos los hospitales a nivel mundial[2], debido a un tardío diagnóstico y dificultad de dar tratamiento a los pacientes infectados, como consecuencia murieron millones de personas[3]. Los síntomas de COVID-19 incluyen fiebre, tos, fatiga y pérdida del gusto o el olfato. El virus se propaga a través de las gotitas respiratorias cuando una persona infectada habla, tose o estornuda[4].



Fig. 1. Virus SARS-CoV-2 causante del COVID-19

Digital Object Identifier: (only for full papers, inserted by LACCEI).
ISSN, ISBN: (to be inserted by LACCEI).
DO NOT REMOVE

Para reducir la propagación del virus, es importante usar máscaras, practicar una buena higiene de manos y mantener el distanciamiento social. Las vacunas también están disponibles para la protección contra COVID-19. Debido a la necesidad de un diagnóstico rápido para evitar la propagación del virus[5], se utilizaron las pruebas rápidas de COVID-19, que permiten confirmar o descartar una infección causada por el virus, desde cualquier lugar, ya que son económicas, portátiles y fáciles de realizar. Estas pruebas rápidas según la Fig.2, fueron diseñados para ser realizados por la persona misma en su hogar, en el kit se incluye una tira reactiva, una solución de extracción y un hisopo para tomar la muestra respiratoria.



Fig. 2. Prueba rápida de Covid19

La persona toma una muestra de su nariz o garganta utilizando el hisopo y la coloca en la solución de extracción. Luego, se coloca una gota de la solución en la tira reactiva y se espera a que aparezca un resultado en la ventana de la prueba. Si el resultado es positivo, significa que la persona tiene una infección activa por COVID-19 y se recomienda buscar atención médica y seguir las recomendaciones de aislamiento y cuidado de la salud. Si el resultado es negativo, no se detectó la presencia del virus en la muestra, pero es importante recordar que las pruebas de antígenos pueden tener una tasa de error y que una persona con síntomas de COVID-19 aún debe buscar atención médica y hacerse una prueba de PCR para confirmar el resultado.

Por lo que mediante inteligencia artificial a través del *deep learning* se busca crear una herramienta que posibilite la detección rápida de COVID-19[6] y le facilite a los médicos un ágil diagnóstico de casos positivos. Las redes neuronales artificiales[7] (*Artificial Neural Networks*, ANN) son un tipo de modelo de inteligencia artificial[8] inspirado en la estructura y funcionamiento de las redes neuronales en el cerebro humano. Se componen de nodos interconectados (neuronas artificiales) que procesan información y toman decisiones basadas en ese procesamiento. ANN se utilizan comúnmente en tareas como el reconocimiento de patrones, la clasificación y la predicción y son uno de los elementos fundamentales dentro del campo del aprendizaje profundo (Deep Learning).

Un tipo de ANN son las denominadas redes neuronales convolucionales (*Convolutional Neural Networks*, CNN), que hoy en día es la arquitectura como Fig.3 que es la elegida

en el área biomédica para el diagnóstico de enfermedades aplicadas al análisis de imágenes[9], cuya finalidad es ayudar al servicio médico en aligerar la atención de pacientes con una detección temprana de síntomas y factores de riesgo del virus COVID-19, debido a la cantidad de pacientes sintomáticos y asintomáticos[10].

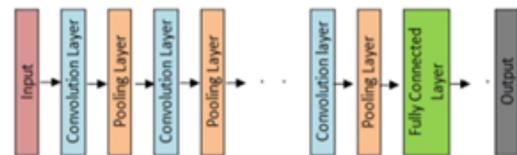


Fig. 3. Arquitectura de una Red Neuronal Convencional

El principal problema de las CNN es que son computacionalmente muy costosas de entrenar[8], estos métodos tienen que utilizar una red más pequeña para entrenar a alta velocidad durante el despliegue. Sin embargo, las redes más pequeñas no tienen mucho poder de diferenciación, debido a esto se ha decidido utilizar un método para aleatorizar las imágenes y re-escalarlas aumentando así la cantidad de ejemplares del dataset que será usado para el entrenamiento de la CNN mejorando su precisión en la clasificación de datos. A su vez, se evalúa el rendimiento del modelo de CNN usando métricas de ML por medio de la plataforma de Google llamada Colab, implementación que será realizada en el lenguaje de programación Python[11].

La Inteligencia Artificial[12] 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[13] que aprenden rápidamente de datos clasificados[14], imágenes o con la propia interacción con los seres humanos. Una de las técnicas de la inteligencia artificial es el *deep learning* [15] la cual cuenta con una arquitectura computacional llamada redes neuronales convolucionales (CNN)[16] 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[17] es capaz de extraer características relacionadas con los resultados clínicos.

El objetivo principal en el presente proyecto fue crear un modelo de inteligencia artificial basado en redes neuronales convolucionales o *Convolutional Neural Networks* - CNN que permita identificar rápidamente si el resultado de las pruebas rápidas de COVID-19 es positivo, negativo e indeterminada.

II. MATERIALES Y METODOS

El Conjunto de Datos

Se cuenta con imágenes de pruebas rápidas de COVID-19, tomadas de red de repositorios públicos, el conjunto de datos o *datasets* consta de 2538 imágenes de pruebas rápidas de casos positivos y negativos de COVID-19, estos datos serán utilizados para entrenar la red neuronal convolucional. Al visualizar el conjunto de datos ver Fig.4 se observa que

contiene 2 carpetas llamadas; pos y neg, a color que serán redimensionadas a 256x256 para que de esta manera su lectura sea más fácil.



Fig. 4 Imágenes del conjunto de datos COVID 19.

La Neurona Artificial

Una neurona artificial, también conocida como perceptrón, es una unidad básica de procesamiento en una red neuronal artificial (ANN, por sus siglas en inglés)[18]. Está diseñada para imitar la función de las neuronas biológicas en el cerebro humano ver Fig.5. La neurona artificial recibe entradas de otros nodos en la red, las procesa y produce una salida. La entrada se multiplica por un peso sináptico, que es ajustado por un algoritmo de entrenamiento para mejorar la precisión de la red. Luego se suma la entrada ponderada con el sesgo, y se aplica una función de activación para producir la salida de la neurona[19]. La función de activación se utiliza para imitar la forma en que las neuronas biológicas se activan o desactivan. Hay varios tipos de funciones de activación, incluyendo la función sigmoidea, la función ReLU y la función tangente hiperbólica[20].

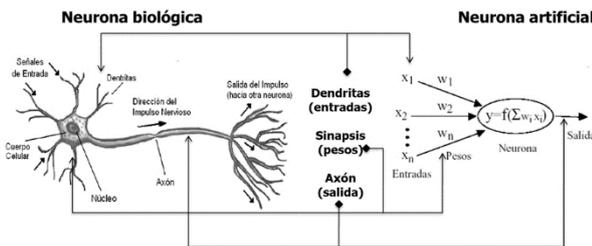


Fig. 5. La Neurona

Redes Neuronales Artificiales (ANN)

Una red neuronal artificial (ANN, por sus siglas en inglés) es un modelo computacional inspirado en la estructura y funcionamiento del cerebro humano[21]. Consiste en un conjunto interconectado de neuronas artificiales (perceptrones) que procesan información en paralelo. Cada neurona en una red neuronal artificial recibe entradas de otras neuronas a través de conexiones ponderadas ver Fig.6. Estas entradas se multiplican por los pesos sinápticos y se suman para producir una activación. Luego, se aplica una función de activación no lineal para producir la salida de la neurona. La información se propaga a través de la red neuronal artificial mediante múltiples capas de neuronas, que se conectan de forma secuencial[22]. La salida de una capa se convierte en la entrada de la siguiente capa hasta que se alcanza la capa de salida, que produce la salida final de la red. Las redes neuronales artificiales se utilizan en una amplia variedad de aplicaciones de aprendizaje automático, incluyendo reconocimiento de patrones, clasificación de imágenes, procesamiento de lenguaje natural, pronóstico financiero y más. Las redes neuronales profundas, que tienen múltiples capas ocultas, son capaces de realizar tareas

extremadamente complejas y son una herramienta poderosa en el campo del aprendizaje automático[23].

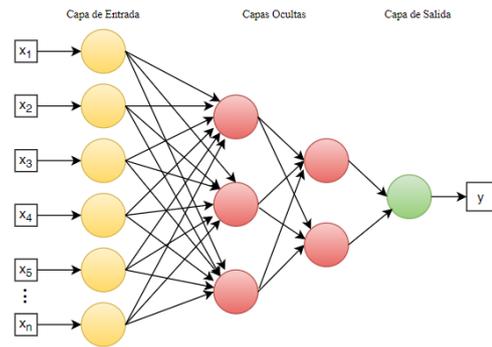


Fig. 6. Red Neuronal Artificial - ANN

Redes Neuronales Convolucionales (CNN)

La Red Neuronal Convolutiva (CNN) según la Fig.7, también llamada ConvNet, es un tipo de red neuronal artificial (CNN)[24], que tiene una arquitectura de avance profundo y tiene una asombrosa capacidad de generalización en comparación con otras redes con capas fully connected[25]. Puede aprender de las características altamente abstractas de los objetos, especialmente los datos espaciales y pueden identificarlos de manera eficiente. Un modelo CNN profundo[26] consiste en un conjunto de capas de procesamiento logran aprender varios objetos o características de los datos que son introducidos como entrada[27].

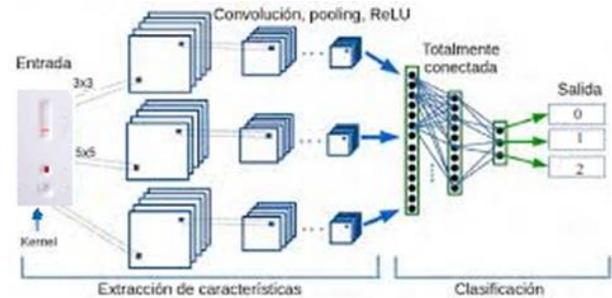


Fig. 7. Red Neuronal Convolutiva - CNN

Capas Convolucionales

La operación de convolución es uno de los bloques de construcción fundamentales de una red neuronal convolutiva[28]. Los parámetros de una capa convolutiva de una CNN consisten en un conjunto de kernels, cada uno es pequeño a lo largo, ancho y alto, pero se extiende a través de completa profundidad del volumen de entrada; los tamaños del kernel tienen valores de 3x3, 5x5, 7x7. Las capas convolucionales aplican filtros convolucionales a la imagen de entrada para extraer características relevantes. Cada filtro es una pequeña matriz de pesos que se desliza por la imagen y produce una nueva matriz de características.

Capas de agrupación (pooling)

Las capas de agrupación reducen la dimensión espacial de las características obtenidas en las capas convolucionales. Esto ayuda a reducir el costo computacional y la cantidad de parámetros de la red.

La Matriz de Confusión

La matriz de confusión es una herramienta comúnmente utilizada en aprendizaje automático para evaluar la precisión de un modelo[29].

		VALORES ESTIMADOS	
		0 (Negativo)	1 (Positivo)
VALORES REALES	0	(TN) Verdaderos Negativos	(FP) Falsos Positivos
	1	(FN) Falsos Negativos	(TP) Verdaderos Positivos

Fig. 8 Matriz de Confusión

Representa un resumen de los resultados correctos e incorrectos de un modelo de clasificación en una tabla de 2x2, con las siguientes categorías ver Fig.8:

Verdaderos Positivos (TP): casos en los que el modelo ha predicho correctamente la clase positiva.

Falsos Positivos (FP): casos en los que el modelo ha predicho incorrectamente la clase positiva.

Verdaderos Negativos (TN): casos en los que el modelo ha predicho correctamente la clase negativa.

Falsos Negativos (FN): casos en los que el modelo ha predicho incorrectamente la clase negativa.

Para usar la matriz de confusión, primero se entrena un modelo y se evalúa en un conjunto de datos de prueba. Luego, se comparan las predicciones del modelo con las etiquetas reales y se llenan los conteos en la matriz de confusión.

Métricas de Predicción

En problemas de clasificación con Machine Learning, se utilizan diferentes métricas para evaluar la precisión de un modelo de predicción[30]. Algunas de las más comunes son:

Accuracy: En (1) es el número de predicciones correctas sobre el número total de predicciones.

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

Precision: En (2) es el número de verdaderos positivos dividido por el número de verdaderos positivos más falsos positivos.

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

Recall (sensibilidad o tasa de detección): En (3) es el número de verdaderos positivos dividido por el número de verdaderos positivos más falsos negativos.

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

F1-Score: En (4) es la media armónica entre precisión y recall.

$$\text{F1-Score} = 2 * ((2) * (3)) / ((2) + (3)) \quad (4)$$

AUC-ROC Curve: Es una métrica que evalúa la capacidad de un modelo de clasificación binaria para discriminar entre dos clases[31].

Es importante seleccionar la métrica adecuada en función del problema de clasificación y de los objetivos específicos del modelo de predicción. Los valores que intervienen en cada una de las métricas provienen de la matriz de confusión.

Procesamiento del Conjunto de Datos

La descarga de los datos se la realiza del sitio Google Drive, se descomprime el archivo .zip, se crea un directorio de entrenamiento que contiene las imágenes de las pruebas rápidas de COVID-19; el set de datos descargado contiene 2 subcarpetas con imágenes de pruebas rápidas positivas y negativas llamadas pos y neg respectivamente.

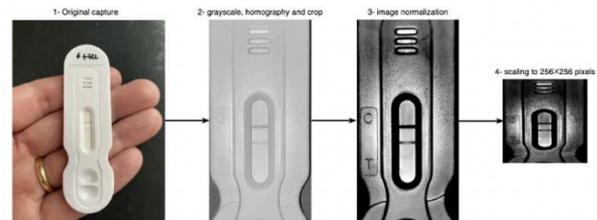


Fig.9 Procesamiento de los Datos

Por lo general en todas las arquitecturas de redes neuronales, se realiza una visualización aleatoria de las imágenes del dataset como se observa en la Fig. 9.

Arquitectura de los Modelos de CNN'S

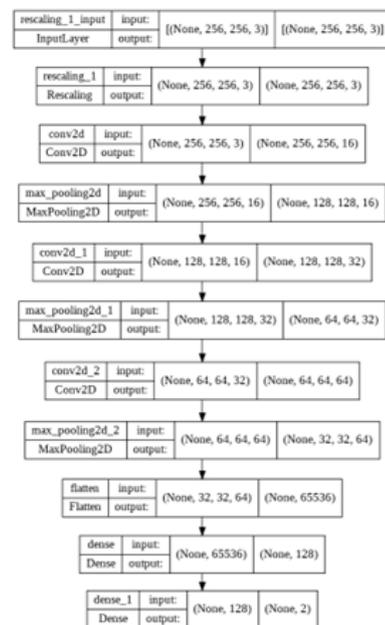


Fig. 10 Modelo de CNN

El modelo de red neuronal convolucional elaborado según la Fig.10, recibe una entrada de 256x256 que es la primera capa convolucional, se usa una serie de 3 capas convolucionales (Conv2D) seguidas por 3 capas de Max-Pooling (MaxPooling2D), se aplicó un filtro que recorrerá toda la imagen, y función de activación ReLU, de esta manera se extraen las características importantes de cada imagen.

El tamaño de la imagen disminuye a medida que se realizan las convoluciones. En la salida de las capas se realizó un aplanamiento para obtener un vector de una dimensión, para finalizar con una capa (Dense) y una capa de salida con la función de activación ReLU luego de aplanar los datos.

Entrenamiento del Modelo de CNN

Se tomo 1046 imágenes de casos positivos y otros 1492 casos negativos de COVID-19 para el entrenamiento de la CNN ver (TABLA I); se dividió el 80% de los datos para el entrenamiento y el 20% de datos para validación.

TABLA I
PARTICIONAMIENTO DEL DATASET

Datos	Train	Test	TOTAL
COVID(1)	836	210	1046
No COVID(0)	1193	299	1492
TOTAL	2029	509	2538

Además, este tipo de redes, pueden identificar rostros, personas, letreros de calles y muchos otros aspectos que contenga datos visuales. Las CNN[32] 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[33]. 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[34].

III.RESULTADO Y DISCUSIÓN

La curva del accuracy obtenida en el entrenamiento de la red neuronal convolucional según la Fig.11 representa la precisión de la red en clasificar correctamente las imágenes de las pruebas rápidas de covid-19 del conjunto de entrenamiento(train) y de prueba(test) a medida que se entrena.

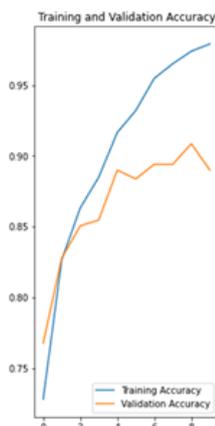


Fig.11. Rendimiento de la CNN

Normalmente, esta curva muestra un aumento en la accuracy a medida que se entrena la red, hasta llegar a un punto en el que se estabiliza o comienza a disminuir debido al sobreajuste. La curva puede ser un indicador útil para determinar cuándo detener el entrenamiento y seleccionar el mejor modelo.

En ambas graficas se puede observar cómo logran convergen los datos en entrenamiento y precisión lo que nos indica que los modelos no cayeron en un *overfitting*. En 10 épocas él tuvo una exactitud o accuracy del 97% y un val_accuracy del 89%.

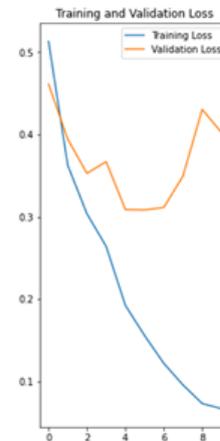


Fig.12. Pérdida en el Entrenamiento de la CNN

Puesto que la pérdida es una medida importante dado que un bajo valor de pérdida indica que el modelo está haciendo predicciones precisas y que se está ajustando bien a los datos de entrenamiento, durante el proceso de aprendizaje de la red neuronal convolucional se observa que en la Fig.12 la curva decrece a medida que se incrementan las épocas, llegándose a alcanzar un *loss* del 6.69% con una exactitud de validación del 89% lo que hace que el modelo no tenga sobreajuste y pueda generalizarse.

IV.CONCLUSIONES

Se detalla de manera resumida el resultado de las métricas de evaluación que obtuvo el modelo de CNN al ser entrenado de dos maneras distintas, primero usando un dataset de imágenes públicas de pruebas rápidas de COVID19 y después utilizando técnicas para aumentar la cantidad de imágenes del dataset.

De las diferentes métricas utilizadas, la métrica considerada como más relevante es la del *accuracy* se obtuvo una diferencia más notoria durante el entrenamiento con imágenes propias vs las imágenes generadas, puesto que aumento en un 7% al utilizar las imágenes generadas.

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%.

Se sabe que una *accuracy* alto, indica que el modelo está realizando predicciones precisas, mientras que un *accuracy* bajo indica que el modelo no está funcionando bien y necesita mejorarse; dentro del proceso de aprendizaje durante la etapa de entrenamiento, el modelo de red neuronal convolucional aprendió a clasificar muy bien, obtuvo un rendimiento considerable con una exactitud(*accuracy*) alcanzada del 97% y una pérdida del 6.69% concluyendo que el modelo puede ser generalizado y está en condiciones para ser usado para la detección del covid19.

REFERENCIAS

- [1] 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.
- [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] L. Rubio Lamia, J. Suárez, I. Santos, S. Martín-de-las-Heras, and F. Martín Cazorra, "Autopsia en muertes por Covid-19: análisis y recomendaciones a través de una revisión," *Rev. Ciencias Forenses Honduras*, vol. 6, no. 1, pp. 14–27, 2020.
- [4] M. Guíñez-Coelho, "Impacto del COVID-19 (SARS-CoV-2) a Nivel Mundial. Implicancias y Medidas Preventivas en la Práctica Dental y sus Consecuencias Psicológicas en los Pacientes," *Int. J. Odontostomatol.*, vol. 14, no. 3, 2020.
- [5] P. A. M. Ramón, "Características clínico-epidemiológicas de la COVID-19 | Perez Abereu | Revista Habanera de Ciencias Médicas," *Revista Habanera de Ciencias Médicas*, 2020. .
- [6] 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.
- [7] B. Martín del Brío and C. Serrano Cinca, "Fundamentos de redes neuronales artificiales: hardware y software," *Scire Represent. y Organ. del Conoc.*, 1995.
- [8] H. Galán and A. Martínez, "Inteligencia artificial . Redes neuronales y Aplicaciones," *Univ. Carlos III Madrid, J.*, 2015.
- [9] S. D. Deb, R. K. Jha, K. Jha, and P. S. Tripathi, "A multi model ensemble based deep convolution neural network structure for detection of COVID19," *Biomed. Signal Process. Control*, vol. 71, 2022.
- [10] D. Patiño Pérez, C. Munive Mora, L. Cevallos-Torres, and M. Botto-Tobar, "Predicción de la Efectividad de las Pruebas Rápidas Realizadas a Pacientes con COVID-19 mediante Regresión Lineal y Random Forest," *Ecuadorian Sci. J.*, vol. 5, no. 2, 2021.
- [11] A. C. Müller and S. Guido, "Introduction to Machine Learning with Python: a guide for data scientists," *Journal of Chemical Information and Modeling*, vol. 53, no. 9, 2016.
- [12] 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.
- [13] 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.
- [14] V. Roman, "Aprendizaje No Supervisado en Machine Learning: Agrupación | by Victor Roman | Ciencia y Datos | Medium," *Medium*, 2019.
- [15] 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.
- [16] H. Alhichri, "CNN Ensemble Approach to Detect COVID-19 from Computed Tomography Chest Images," *Comput. Mater. Contin.*, vol. 67, no. 3, 2021.
- [17] J. Díaz-Ramírez, "Aprendizaje Automático y Aprendizaje Profundo," *Ingeniare. Rev. Chil. Ing.*, vol. 29, no. 2, 2021.
- [18] D. Patiño Pérez, M. Botto-Tobar, and C. Munive Mora, "Predicción del Composite Requerido en el Diseño de un Recipiente Toroidal Mediante una Red Neuronal Artificial," *Investig. Tecnol. e Innovación*, vol. 13, no. 13, 2021.
- [19] J. Archila Rodríguez, "La neurona," *LA Neurona*, 2017.
- [20] J. A.-T. Barrera, "Redes Neuronales Artificiales," *Univ. Guadalajara*, p. 276, 2016.
- [21] E. S. M. A. Serna, and E. Acevedo, "Principios y características de las redes neuronales artificiales," *Desarro. e Innovación en Ing. Segunda Edición*, 2017.
- [22] O. Agasi, J. Anderson, A. Cole, M. Berthold, M. Cox, and D. Dimov, "What is an Artificial Neural Network (ANN)? - Definition from Techopedia," *Techopedia*, 2018.
- [23] D. Patiño Perez, R. Silva Bustillos, M. Botto-Tobar, and C. Munive Mora, "Análisis de Imágenes de Rayos X por Medio de Redes Neuronales Artificiales," *Ecuadorian Sci. J.*, vol. 5, no. 1, 2021.
- [24] D. Calvo, "Red Neuronal Convolutacional CNN," *Diego Calvo*, 2017. [Online]. Available: <http://www.diegocalvo.es/red-neuronal-convolutacional/>.
- [25] M. Zambrano-Vizueta *et al.*, "Segmentation of Medical Image Using Novel Dilated Ghost Deep Learning Model," *Comput. Intell. Neurosci.*, vol. 2022, 2022.
- [26] A. M. Giancarlo Zaccone, Md. Rezaul Karim *et al.*, "Deep Learning With Python Develop Deep Learning Models On Theano And TensorFlow Using Keras," *Mach. Learn. Using R*, vol. 26, no. 3, 2019.
- [27] J. Monroy-de-Jesús, A. Reyes-Nava, and F. Olmos, "Clasificador de plantas medicinales por medio de Deep Learning," *Res. Comput. Sci.*, vol. 148, no. 7, 2019.
- [28] V. Maeda, C. Guerrero, C. Olvera, M. Araiza, G. Espinoza, and R. Bordón, "Redes neuronales convolucionales para la detección y clasificación de enfermedades de plantas basadas en imágenes digitales," *Rev. Científica Biológico Agropecu. Tuxpan*, vol. 6, 2018.
- [29] Abhishek Sharma, "Confusion Matrix in Machine Learning," *Www.GeeksforgEEKS.Org*, 2018.
- [30] 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.
- [31] R. Delgado, "Introducción a la Validación Cruzada (k-fold Cross Validation) en R," *R Pubs*, 2018.
- [32] L. Alzubaidi *et al.*, "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *J. Big Data*, vol. 8, no. 1, 2021.
- [33] 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.
- [34] R. Jiménez Moreno, O. Avilés, and D. M. Ovalle, "Red neuronal convolutacional para discriminar herramientas en robótica asistencial," *Visión electrónica*, vol. 12, no. 2, 2018.