




UNIVERSIDAD ANDINA DEL CUSCO

FACULTAD DE CIENCIAS DE LA SALUD

ESCUELA PROFESIONAL DE MEDICINA HUMANA



TESIS:

USO DE INTELIGENCIA ARTIFICIAL PARA EL DIAGNÓSTICO DE COVID-19
A TRAVÉS DE RADIOGRAFÍA DE TÓRAX EN EL HOSPITAL NACIONAL
ADOLFO GUEVARA VELASCO, HOSPITAL REGIONAL Y HOSPITAL
ANTONIO LORENA, CUSCO-PERÚ, PERIODO 2020-2021

Presentado por los bachilleres:

Luna Mancilla, Pavel Edmundo

Vargas Quisca, Sharon Angelica

Para optar el título Profesional de Médico Cirujano

Asesor: Mtro.Med. Erick Flores Revilla

CUSCO - PERÚ

Agosto de 2022



AGRADECIMIENTOS

A todos.

DEDICATORIA

Quisiera dedicar esta tesis a mi familia. No podría haberlo hecho sin su apoyo y amor. También me gustaría agradecer a mis gatos: Tito, Chester, Lina y Valentina por estar ahí para mí todo el tiempo.

Atte. Los Autores



DICTAMINANTES

Dr.Med. William Senen Sarmiento Herrera

Med. Hugo Rommel Villagarcía Zereceda

REPLICANTES

Dra. Herminia Naveda de Aramburú

Med. Juan Carlos Rojas Marroquin

ASESOR

Mtro.Med. Erick Gustavo Flores Revilla



ÍNDICE

CAPITULO I: INTRODUCCIÓN.....	9
1.1 Planteamiento del problema.....	9
1.2 Formulación del problema.....	10
1.2.1 Problema general.....	10
1.2.2 Problemas específicos.....	10
1.3 Objetivo de investigación.....	10
1.3.1 Objetivo general.....	10
1.3.2 Objetivos específicos.....	10
1.4 Justificación de la investigación.....	11
1.5 Aspectos éticos.....	11
CAPITULO II: MARCO TEÓRICO CONCEPTUAL.....	12
2.1 Antecedentes teóricos.....	12
2.1.1 Antecedentes Internacionales.....	12
2.1.2 Antecedentes nacionales, regionales y locales.....	29
2.2 Bases Teóricas.....	29
2.2.1 COVID-19.....	29
2.2.2 Inteligencia Artificial.....	40
2.2.3 Radiografía de tórax como método de detección de COVID-19.....	44
2.3 Definición de términos básicos.....	45
2.4 Hipótesis.....	46
2.5 Variables.....	48
2.5.1 Identificación de Variables.....	48



2.5.2	Operacionalización de variables	49
CAPITULO III: MÉTODO		51
3.1	Alcance del estudio	51
3.2	Tipo de investigación.....	51
3.3	Diseño de investigación.....	51
3.4	Población y muestra.....	51
3.4.1	Descripción de la población.....	51
3.4.2	Criterios inclusión y exclusión	52
3.4.3	Muestra: tamaño y métodos de muestreo	53
3.5	Técnicas, instrumentos y procedimientos de recolección de datos.....	54
3.6	Plan de análisis de datos	55
3.6.1	Técnicas estadísticas para la recolección de datos.....	55
3.6.2	Base de Datos.....	56
CAPÍTULO IV: RESULTADOS DE LA INVESTIGACIÓN.....		58
CAPÍTULO V: DISCUSIÓN		62
5.1	Descripción de los hallazgos más relevantes y significativos	62
5.2	Limitaciones del estudio	62
5.3	Comparación crítica con la literatura existente.....	63
5.4	Implicancias del estudio.....	66
CONCLUSIONES		67
RECOMENDACIONES.....		67
BIBLIOGRAFÍA		69
ANEXOS		74



ÍNDICE DE GRÁFICOS

Figura 1. Esquema de una red neuronal artificial.	42
Figura 2. Curva ROC.....	61

ÍNDICE DE TABLAS

Tabla 1. Distribución de placas tomadas de pacientes por sexo.....	58
Tabla 2. Distribución de edades de placas de pacientes sin la enfermedad.....	59
Tabla 3. Distribución de placas de pacientes con la enfermedad.....	60
Tabla 4. Tabla de confusión.....	60
Tabla 5. Resultados de desempeño del diagnóstico por IA para la COVID 19.....	61



RESUMEN

Hoy en día se ha encontrado grandes avances en las técnicas diagnósticas de aprendizaje profundo aplicado a imágenes, lo cual supone un nuevo punto de acceso al diagnóstico. El objetivo de la siguiente tesis propone una nueva prueba diagnóstica basada en el uso de aprendizaje automático aplicado a radiografías de tórax para hacer el diagnóstico de COVID-19, para lo cual se recolectó datos de las historias clínicas y radiografías de tórax del Hospital Regional del Cusco, Adolfo Guevara Velasco y Antonio Lorena en periodo 2020 a 2021 para los casos COVID-19 y periodo 2019 para los casos no COVID.19. Esto nos permitió evaluar la sensibilidad de la clasificación e imágenes de radiografía de tórax mediante el aprendizaje automático al ser comparada frente al estándar de oro para diagnóstico de COVID-19 la prueba de RT-PCR y prueba antigénica. El diagnóstico de COVID-19 por IA logró una sensibilidad de 90.13%, especificidad de 80.91%, valor predictivo positivo de 70.24%, valor predictivo negativo de 94.25% y una precisión de 83.98%. Convirtiéndola en una herramienta adecuada para el diagnóstico de COVID-19.

Palabras clave: COVID-19, radiografía de tórax, inteligencia artificial, aprendizaje automático, clasificación de imágenes, prueba diagnóstica.



ABSTRACT

Nowadays, great advances have been found in deep learning diagnostic techniques applied to images, which stands for a new point of access to diagnosis. The objective of the following thesis proposes a new diagnostic test based on the use of machine learning applied to chest X-rays to make the diagnosis of COVID-19, for which data was collected from the medical records and chest X-rays of the Hospital Regional del Cusco, Adolfo Guevara Velasco and Antonio Lorena in the 2020 to 2021 period for COVID-19 cases and the 2019 period for non-COVID-19 cases. This allowed us to assess the sensitivity of machine learning chest x-ray imaging and classification when compared to the gold standard for COVID-19 diagnosis, RT-PCR and antigen testing. The diagnosis of COVID-19 by AI achieved a sensitivity of 90.13%, a specificity of 80.91%, a positive predictive value of 70.24%, a negative predictive value of 94.25%, and an accuracy of 83.98%. Making it a suitable tool for the diagnosis of COVID-19.

Keywords: COVID-19, chest radiograph, artificial intelligence, machine learning, image classification, diagnostic test.



CAPITULO I: INTRODUCCIÓN

1.1 Planteamiento del problema

El COVID 19 es un problema de salud pública que tiene gran impacto en el país desde marzo 2020 hasta la fecha. Durante la primera ola de la pandemia, los establecimientos de salud no contaban con las herramientas suficientes para un diagnóstico acertado y oportuno al alcance de todos los ciudadanos, esto tuvo como consecuencia el diagnóstico y tratamiento tardío y/o erróneo de pacientes que padecían la COVID-19, esto se tradujo en una mayor morbimortalidad [1,2].

Según la resolución ministerial N° 905 – 2020- MINSA la definición de caso sospechoso es una persona con infección respiratoria aguda y al menos alguno de los síntomas típicos de COVID 19, para los casos probables se agrega a esto el nexo epidemiológico o imagenología; para el diagnóstico de caso confirmado al caso sospechoso más una prueba molecular RT-PCR o una prueba antigénica [3]. La definición de caso sospechoso y parte de los casos probables no permite el diferenciar un caso COVID 19 de sus diagnósticos alternativos como una faringitis o neumonía de otra causa viral. Esto trae consecuencias indeseables para los pacientes que no padecen de la enfermedad, pero son considerados casos sospechosos, debido a que deben de realizar aislamiento domiciliario obligatorio de 7 días aproximadamente [4,5].

Proponemos una prueba diagnóstica rápida, accesible, no invasiva y de bajo costo, que permite la diferenciación con una radiografía de tórax en cualquier paciente considerado caso sospechoso, entre padecer o no de COVID 19.



1.2 Formulación del problema

1.2.1 Problema general

¿Cuál es la sensibilidad y la especificidad de la inteligencia artificial para el diagnóstico de COVID 19?

1.2.2 Problemas específicos

- ¿Cuál es el valor predictivo positivo de la inteligencia artificial para el diagnóstico de COVID 19?
- ¿Cuál es el valor predictivo negativo de la inteligencia artificial para el diagnóstico de COVID 19?
- ¿Cuál es la precisión de la inteligencia artificial para el diagnóstico de COVID 19?

1.3 Objetivo de investigación

1.3.1 Objetivo general

Determinar la sensibilidad y la especificidad de la inteligencia artificial para el diagnóstico de COVID 19.

1.3.2 Objetivos específicos

- Determinar el valor predictivo positivo de la inteligencia artificial para el diagnóstico de COVID 19
- Determinar el valor predictivo negativo de la inteligencia artificial para el diagnóstico de COVID 19
- Determinar la precisión de la inteligencia artificial para el diagnóstico de COVID 19



1.4 Justificación de la investigación

Esta investigación permitirá describir la sensibilidad y especificidad de esta prueba diagnóstica con relación a la prueba de oro RT-PCR.

Si la prueba diagnóstica tiene alta sensibilidad y especificidad potencialmente podrá ser utilizada en zonas donde la prueba diagnóstica RT-PCR no esté disponible y la radiografía de tórax sí, para el diagnóstico de COVID 19.

1.5 Aspectos éticos

Para la realización de este estudio se solicitó la autorización del Comité de Ética del Hospital Nacional Adolfo Guevara Velasco, Hospital Regional del Cusco y Hospital Antonio Lorena.

Para realizar la investigación en los tres hospitales, se tomaron los datos de las historias clínicas y las radiografías del departamento de radiología, por lo que este estudio no requirió de autorización del paciente, la obtención de información fue de manera indirecta.

Se siguieron los protocolos de Helsinsky y similares en respeto de los derechos y la dignidad de la población estudiada; respetando la privacidad del paciente, su familia y la institución. Se omitió cualquier dato irrelevante para el estudio y se garantizó en todo momento la confidencialidad de la información.



CAPITULO II: MARCO TEÓRICO CONCEPTUAL

2.1 Antecedentes teóricos

2.1.1 Antecedentes Internacionales

Shuo Wang, Yunfei Zha, Weimin Li, Qingxia Wu, Xiaohu Li, Meng Niu (Wuhan, Henan, Anhui, Heilongjiang, Beijing, Huangshi - China, marzo 2020) “**A fully automatic deep learning system for COVID-19 diagnostic and prognostic analysis**” que traducido al español es un sistema de aprendizaje profundo completamente automático para el análisis de diagnóstico y pronóstico COVID-19. **Resumen** La enfermedad del COVID-19 se ha extendido a nivel mundial y los recursos médicos se vuelven insuficientes en muchas regiones. Es importante realizar un diagnóstico rápido de COVID-19 y encontrar pacientes de alto riesgo con peor pronóstico para la prevención temprana y la optimización de los recursos médicos. Aquí, propusieron un sistema de aprendizaje profundo completamente automático para el análisis de diagnóstico y pronóstico de COVID-19 mediante tomografía computarizada de uso rutinario. **Métodos:** Recolectaron retrospectivamente 5372 pacientes con imágenes de tomografía computarizada de siete ciudades o provincias. En primer lugar, se utilizaron 4106 pacientes con imágenes de tomografía computarizada para entrenar previamente el sistema de aprendizaje profundo, haciéndolo aprender las características pulmonares. Posteriormente, se inscribieron 1266 pacientes (924 con COVID-19 y 342 con otras neumonías) de seis ciudades o provincias para capacitar y validar externamente el desempeño del sistema de aprendizaje profundo. **Resultados:** En los cuatro conjuntos de validación externa, el sistema de aprendizaje profundo logró un buen rendimiento en la identificación de COVID-19 de otras neumonías (AUC 0,87 y 0,88, respectivamente) y neumonía viral (AUC 0,86). Además, el sistema de aprendizaje profundo logró estratificar a los pacientes en grupos de alto y bajo riesgo cuyo tiempo de estadía en el hospital tuvo una diferencia significativa ($p =$



0.013 y $p = 0.014$, respectivamente). Sin ayuda humana, el sistema de aprendizaje profundo se centró automáticamente en áreas anormales que mostraban características consistentes con los hallazgos radiológicos informados. **Conclusiones:** El aprendizaje profundo proporciona una herramienta conveniente para la detección rápida de COVID-19 y la identificación de posibles pacientes de alto riesgo, lo que puede ser útil para la optimización de los recursos médicos y la prevención temprana antes de que los pacientes muestren síntomas graves [6].

Julian D. Arias – Londoño, Laureano Moro-Velázquez y Juan I. Godino-Llorente. (Center for Language and Speech Processing - EEUU diciembre 2020) “**Artificial Intelligence Applied to Chest X-Ray Images for the Automatic Detection of COVID-19. A Thoughtful Evaluation Approach**” que traducido al español es Inteligencia artificial aplicada a imágenes de rayos X de tórax para la detección automática de COVID-19. Un enfoque de evaluación reflexivo. El análisis combinado tiene como objetivo reducir el número significativo de falsos negativos de estas pruebas y proporcionar evidencia complementaria sobre la presencia y gravedad de la enfermedad. Sin embargo, el procedimiento no está exento de errores y la interpretación de la radiografía de tórax solo está restringida a los radiólogos debido a su complejidad. **Objetivo** proporcionar nueva evidencia para el diagnóstico, este artículo presenta una evaluación de diferentes métodos basados en una red neuronal profunda. Estos son los primeros pasos para desarrollar una herramienta de diagnóstico automático de COVID-19 utilizando imágenes de rayos X de tórax para diferenciar entre controles, neumonía o grupos de COVID-19. **Método** El documento describe el proceso seguido para entrenar una red neuronal convolucional con un conjunto de datos de más de 79, 500 imágenes de rayos X compiladas de diferentes fuentes, incluidos más de 8, 500 ejemplos de COVID-19. Se llevan a cabo tres experimentos diferentes siguiendo tres esquemas de preprocesamiento para evaluar y



comparar los modelos desarrollados. El objetivo es evaluar cómo el procesamiento previo de los datos afecta los resultados y mejora su explicabilidad. Asimismo, se realiza un análisis crítico de diferentes aspectos de variabilidad que puedan comprometer el sistema y sus efectos. **Resultados** Con la metodología empleada se obtiene una precisión de clasificación del 91,5%, con un 87,4% de recordatorio promedio para el peor pero más explicable experimento, que requiere una segmentación automática previa de la región pulmonar. **Conclusiones**, En cualquier caso, el despliegue de estos algoritmos no está exento de controversias: alojar los modelos de IA en un servicio en la nube implicaría cargar las imágenes que podrían estar sujetas a normativas y restricciones nacionales e internacionales para garantizar la privacidad [7].

Ali Al-Bawi, Karrar Al-Kaabi, Mohammed Jeryo y Ahmad Al-Fatlawi1 (Kufa - Iraq, Mashhad - Iran, mayo 2020) “*CCBlock: an effective use of deep learning for automatic diagnosis of COVID-19 using X-ray images*” que traducido al español es CCBlock: un uso eficaz del aprendizaje profundo para el diagnóstico automático de COVID-19 mediante imágenes de rayos X. **Propuesta:** Es necesario considerar el desarrollo de métodos de asistencia para detectar y diagnosticar el COVID-19. Basados en redes neuronales convolucionales (CNN), los sistemas de detección automatizados han mostrado resultados prometedores en el diagnóstico de pacientes con COVID-19 mediante radiografía; por lo tanto, se presentan como una solución viable para el diagnóstico de COVID-19. **Materiales y métodos:** Basado en la mejora de la red del grupo de geometría visual clásica (VGG) con el bloque convolucional de COVID (CCBlock), en este estudio se propuso un modelo de detección eficiente para diagnosticar y distinguir a los pacientes con COVID-19 de aquellos con neumonía y personas sanas. a través de radiografía. El conjunto de datos de prueba del modelo incluyó 1.828 imágenes de rayos X disponibles en plataformas públicas. 310 imágenes mostraban casos



confirmados de COVID-19, 864 imágenes que indicaban casos de neumonía y 654 imágenes que mostraban personas sanas. **Resultados:** De acuerdo con los resultados de la prueba, la mejora de la red VGG clásica con radiografía proporcionó el mayor rendimiento de diagnóstico y una precisión general del 98,52% para dos clases, así como una precisión del 95,34% para tres clases. **Conclusiones:** Según los resultados, el uso de la red neuronal profunda VGG mejorada puede ayudar a los radiólogos a diagnosticar automáticamente el COVID-19 mediante radiografía [8].

Kiran Purohit, Abhishek Kesarwani, Dakshina Ranjan Kisku, and Mamata Dalui (Durgapur – India, octubre 2020) “*COVID-19 Detection on Chest X-Ray and CT Scan Images Using Multi-image Augmented Deep Learning Model*” que traducido al español es Detección de COVID-19 en radiografías de tórax e imágenes de tomografía computarizada utilizando un modelo de aprendizaje profundo aumentado de múltiples imágenes. **Introducción:** Para ayudar a la metodología tradicional de RT-PCR para un diagnóstico clínico preciso, la detección de COVID-19 se puede adoptar con imágenes de rayos X y tomografía computarizada del pulmón de un individuo. **Método:** el presente artículo informa sobre una técnica de aumento de múltiples imágenes basada en una red neuronal convolucional (CNN) para detectar COVID-19 en imágenes de rayos X de tórax y tomografía computarizada de tórax de individuos sospechosos de coronavirus. El aumento de múltiples imágenes hace uso de la información de discontinuidad obtenida en las imágenes filtradas para aumentar el número de ejemplos efectivos para entrenar el modelo CNN. **Resultados:** Con este enfoque, el modelo propuesto exhibe una mayor precisión de clasificación alrededor del 95,38% y 98,97% para imágenes de tomografía computarizada y rayos X, respectivamente. Las imágenes de tomografía computarizada con aumento de múltiples imágenes logran una sensibilidad del 94,78% y una especificidad del 95,98%, mientras que las imágenes de rayos X con aumento de múltiples



imágenes logran una sensibilidad del 99,07% y una especificidad del 98,88%. La evaluación se ha realizado en bases de datos disponibles públicamente que contienen imágenes de rayos X de tórax y tomografías computarizadas y los resultados experimentales también se comparan con los modelos ResNet-50 y VGG-16.

Conclusiones: Se encontró que los resultados experimentales son muy convincentes y surgieron como una aplicación útil para la detección de COVID-19 en imágenes de rayos X de tórax y tomografías computarizadas de individuos con sospecha de COVID 19. Las respuestas sutiles de diversas anomalías como tuberculosis, neumonía, influenza, etc., confunden al clasificador y restringen el funcionamiento del sistema. Los trabajos futuros pueden incluir la detección de múltiples afecciones, como neumonía, bronquitis y tuberculosis, junto con COVID-19 de personas sospechosas de tener una enfermedad respiratoria [9].

Murphy, K., Smits, Henk, Knoop, Arnoud J. G., Korst, Michael B. J. M, Samson, Tijs Scholten, Ernst T., Schalekamp, Steven, et.al. (Huden, Hertogenbosch, Amersfoort, Thirona, Nijmegen - Países Bajos septiembre 2020) “**COVID-19 on Chest Radiographs: A Multireader Evaluation of an Artificial Intelligence System**” que traducido al español es *COVID-19 en radiografías de tórax: una evaluación de múltiples lectores de un sistema de inteligencia artificial*. **Justificación** La radiografía de tórax puede desempeñar un papel importante en la clasificación de la enfermedad por coronavirus 2019 (COVID-19), particularmente en entornos de bajos recursos. **Objetivo** Evaluar el desempeño de un sistema de inteligencia artificial (IA) para la detección de neumonía COVID-19 en radiografías de tórax. **Materiales y métodos** Se entrenó un sistema de IA (CAD4COVID-XRay) en 24 678 radiografías de tórax, incluidas 1540 utilizadas solo para validación durante el entrenamiento. El conjunto de prueba consistió en un conjunto de radiografías de tórax adquiridas continuamente (n= 454) obtenido en



pacientes con sospecha de neumonía por COVID-19 entre el 4 de marzo y el 6 de abril de 2020, en un centro (223 pacientes con resultados positivos de la reacción en cadena de la polimerasa con transcripción inversa [RT-PCR], 231 con resultados negativos de la RT-PCR). Las radiografías fueron analizadas de forma independiente por seis lectores y por el sistema de inteligencia artificial. El rendimiento diagnóstico se analizó con la curva característica de funcionamiento del receptor. **Resultados** Para el conjunto de prueba, la edad media de los pacientes fue de 67 años \pm 14,4 (desviación estándar) (56% hombres). Con los resultados de la prueba de RT-PCR como estándar de referencia, el sistema de IA clasificó correctamente las radiografías de tórax como neumonía COVID-19 con un área bajo la curva característica de funcionamiento del receptor de 0,81. El sistema superó significativamente a cada lector ($P < 0,001$ utilizando la prueba de McNemar) en sus sensibilidades más altas posibles. En sus sensibilidades más bajas, solo un lector superó significativamente al sistema de inteligencia artificial ($P = .04$). **Conclusión** El rendimiento de un sistema de inteligencia artificial en la detección de la enfermedad por coronavirus 2019 en radiografías de tórax fue comparable al de seis lectores independientes [10].

Linda Wang, Zhong Qiu Lin y Alexander Wong (Waterloo – Canadá, noviembre 2020)
“COVID-Net: a tailored Deep convolutional neural network design for detection of COVID-19 cases from chest X-ray images” que traducido al español es COVID-Net: un diseño de red neuronal convolucional profunda a medida para la detección de casos de COVID-19 a partir de imágenes de rayos X de tórax. **Resumen** En los primeros estudios se encontró que los pacientes presentan anomalías en las imágenes de la radiografía de tórax que son características de los infectados con COVID-19. **Materiales y métodos:** Motivados por esto e inspirados por los esfuerzos de código abierto de la comunidad de investigadores, en este estudio presentamos COVID-Net, un diseño de red neuronal



convolucional profunda diseñado para la detección de casos de COVID-19 a partir de imágenes de rayos X de tórax que es código abierto y disponible para el público en general. **Resultados:** Según el leal saber y entender de los autores, COVID-Net es uno de los primeros diseños de red de código abierto para la detección de COVID-19 a partir de imágenes de radiografía de tórax en el momento del lanzamiento inicial. También presentamos COVIDx, un conjunto de datos de referencia de acceso abierto que generamos que comprende 13,975 radiografías de tórax en 13,870 casos de pacientes, con el mayor número de casos positivos de COVID-19 disponibles públicamente según el mejor conocimiento de los autores. **Conclusiones:** COVID-Net hace predicciones utilizando un método de explicabilidad en un intento no solo de obtener conocimientos más profundos sobre los factores críticos asociados con los casos de COVID, que pueden ayudar a los médicos a mejorar la detección, sino también auditar COVID-Net de manera responsable y transparente. manera de validar que está tomando decisiones basadas en información relevante de las imágenes de radiografía de tórax [11].

Javor, D., Kaplan, H., Kaplan, A., Puchner, S. B., Krestan, C., Baltzer, P. (Vienna - Austria, noviembre 2020) *“Deep learning analysis provides accurate COVID-19 diagnosis on chest computed tomography”* que traducido al español es El análisis de aprendizaje profundo proporciona un diagnóstico COVID-19 preciso en la tomografía computarizada de tórax. **Introducción:** La tomografía computarizada es una herramienta de diagnóstico esencial en el tratamiento de COVID-19. Teniendo en cuenta la gran cantidad de exámenes en escenarios de alta carga de casos, una herramienta automatizada podría facilitar y ahorrar un tiempo crítico en el diagnóstico y la estratificación del riesgo de la enfermedad. **Métodos:** Se desarrolló un nuevo clasificador de aprendizaje automático (ML) derivado del aprendizaje profundo utilizando un enfoque de programación simplificado y un conjunto de datos de código abierto que consta de 6868



imágenes de TC de tórax de 418 pacientes que se dividió en subconjuntos de entrenamiento y validación. Luego, el rendimiento diagnóstico se evaluó y se comparó con radiólogos experimentados en un conjunto de datos de pruebas independientes. Las métricas de rendimiento de diagnóstico se calcularon mediante el análisis de las características operativas del receptor (ROC). Se identificaron y validaron los puntos operativos con razones de probabilidad altas positivas (> 10) y bajas negativas (< 0.01) para estratificar el riesgo de presencia de COVID-19. **Resultados:** El modelo logró una precisión general de 0,956 (AUC) en un conjunto de datos de pruebas independientes de 90 pacientes. Se identificaron y probaron tanto los umbrales de entrada como de descarte. En el punto de operación de la regla, la sensibilidad y la especificidad fueron 84,4% y 93,3% y no difirieron de ambos radiólogos ($p > 0,05$). En el umbral de descarte, la sensibilidad (100%) y la especificidad (60%) difirieron significativamente de los radiólogos ($p < 0,05$). Las razones de probabilidad y un nomograma de Fagan proporcionan estimaciones de rendimiento de prueba independientes de la prevalencia. **Conclusión:** El diagnóstico preciso de COVID-19 utilizando un enfoque básico de aprendizaje profundo es factible utilizando datos de imágenes de TC de código abierto. Además, el clasificador de aprendizaje automático provisto de criterios validados de entrada y salida de reglas podría usarse para estratificar el riesgo de presencia de COVID-19 [12].

Minghuan Wang, Chen Xia, Lu Huang, Shabei Xu, Chuan Qin, Jun Liu, Ying Cao y et.al. (Wuhan, Xianning, Changsha - China, octubre 2020) **“Deep learning-based triage and analysis of lesion burden for COVID-19: a retrospective study with external validation”** que traducido al español es Triage basado en aprendizaje profundo y análisis de la carga de lesiones para COVID-19: un estudio retrospectivo con validación externa.

Justificación: La identificación rápida de los pacientes con sospecha de COVID-19 es



crucial para el control de la enfermedad. **Objetivo** desarrollar un algoritmo de aprendizaje profundo sobre la base de la TC de tórax para una clasificación rápida en las clínicas de fiebre. **Métodos:** Entrenamos un modelo basado en U-Net en tomografías computarizadas de tórax sin contraste obtenidas de 2447 pacientes ingresados en el Hospital Tongji (Wuhan, China) entre el 1 de febrero de 2020 y el 3 de marzo de 2020 (1647 pacientes con COVID-19 confirmado por RT-PCR y 800 pacientes sin COVID-19) para segmentar opacidades pulmonares y alertar casos con manifestaciones de imagen de COVID-19. La capacidad de la inteligencia artificial (IA) para clasificar a los pacientes sospechosos de tener COVID-19 se evaluó en un gran conjunto de validación externa, que incluyó 2120 casos consecutivos recopilados retrospectivamente de tres clínicas de fiebre dentro y fuera del centro epidémico de Wuhan (Hospital Tianyou [Wuhan, China; área de alta prevalencia de COVID-19], Hospital Central de Xianning [Xianning, China; área de prevalencia media de COVID-19], y The Second Xiangya Hospital [Changsha, China; área de baja prevalencia de COVID-19]). **Resultados:** En el conjunto de validación externa, utilizando los informes radiológicos como estándar de referencia, el triaje asistido por IA logró un área bajo la curva de 0.953 (IC del 95%: 0.949–0.959), con una sensibilidad de 0.923 (95 % IC 0.914–0.932), especificidad de 0.851 (0.842–0.860), un valor predictivo positivo de 0.790 (0.777–0.803) y un valor predictivo negativo de 0.948 (0.941–0.954). La IA tardó una mediana de 0.55 min (IQR: 0.43–0.63) para marcar un caso positivo, mientras que los radiólogos tardaron una mediana de 16.21 min (11.67–25.71) para redactar un informe y 23.06 min (15.67–39.20) para publicar un informe. Con respecto a la identificación de aumentos en la carga de lesiones, la IA alcanzó una sensibilidad de 0.962 (IC del 95%: 0.947–1.000) y una especificidad de 0.875 (IC del 95%: 0.833–0.923). La concordancia entre IA y el panel de radiólogos fue alta (coeficiente kappa de Cohen 0.839, IC del 95%: 0.718–0.940). **Conclusiones:** Dada su



alta precisión en poblaciones con prevalencia variada de COVID-19, la integración de este sistema en el flujo de trabajo clínico estándar podría acelerar la identificación de tomografías computarizadas de tórax con indicaciones de imagen de COVID-19 [13].

Minaee, S., Kafieh, R., Sonka, M., Yazdani, S., Jamalipour Soufi, G. (Isfahán - Irán, Seattle - EEUU, julio 2020) “**Deep-COVID: Predicting COVID-19 from chest X-ray images using deep transfer learning**” que traducido al español es *Deep-COVID:*

predicción de COVID-19 a partir de imágenes de rayos X de tórax mediante el aprendizaje de transferencia profunda. **Resumen** Uno de los pasos cruciales en la lucha contra el COVID-19 es la capacidad de detectar a los pacientes infectados con la suficiente antelación y ponerlos bajo cuidados especiales. La detección de esta enfermedad a partir de imágenes radiográficas y radiológicas es quizás una de las formas más rápidas de diagnosticar a los pacientes. Algunos de los primeros estudios mostraron anomalías específicas en las radiografías de tórax de pacientes infectados con COVID-19. **Objetivo** aplicación de modelos de aprendizaje profundo para detectar pacientes con COVID-19 a partir de sus imágenes de radiografía de tórax. **Materiales y métodos** Primero se preparó un conjunto de datos de 5000 radiografías de tórax a partir de los conjuntos de datos disponibles públicamente. Las imágenes que muestran la presencia de la enfermedad COVID-19 fueron identificadas por un radiólogo certificado por la junta. El aprendizaje por transferencia en un subconjunto de 2000 radiogramas se utilizó para entrenar cuatro redes neuronales convolucionales populares, incluidas ResNet18, ResNet50, SqueezeNet y DenseNet-121, para identificar la enfermedad COVID-19 en las imágenes de rayos X de tórax analizadas. **Resultados** Evaluamos estos modelos en las 3000 imágenes restantes, y la mayoría de estas redes lograron una tasa de sensibilidad del 98% ($\pm 3\%$), mientras que tenían una tasa de especificidad de alrededor del 90%. Además de las tasas de sensibilidad y especificidad, también



presentamos la curva de característica operativa del receptor (ROC), la curva de precisión-recuperación, la predicción promedio y la matriz de confusión de cada modelo. También usamos una técnica para generar mapas de calor de regiones pulmonares potencialmente infectadas por COVID-19 y mostrar que los mapas de calor generados contienen la mayoría de las áreas infectadas anotadas por nuestro radiólogo certificado por la junta. **Conclusiones** Si bien el rendimiento logrado es muy alentador, se requieren más análisis en un conjunto más grande de imágenes COVID-19 para tener una estimación más confiable de las tasas de precisión [14].

Wehbe, R., Sheng, J., Dutta, S., Chai, S., Dravid, A., Barutcu, S., et. al. (Chicago, Evaston - EEUU, noviembre 2020) “**DeepCOVID-XR: An Artificial Intelligence Algorithm to Detect COVID-19 on Chest Radiographs Trained and Tested on a Large US Clinical Dataset Article**” que traducido al español es *DeepCOVID-XR: un algoritmo de inteligencia artificial para detectar COVID-19 en radiografías de tórax entrenado y probado en un gran conjunto de datos clínicos de EE. UU.* **Objetivo** Presentar DeepCOVID-XR, un algoritmo de inteligencia artificial de aprendizaje profundo para detectar COVID-19 en radiografías de tórax, entrenado y probado en un gran conjunto de datos clínicos. **Materiales y métodos** DeepCOVID-XR es un conjunto de redes neuronales convolucionales para detectar COVID-19 en radiografías frontales de tórax utilizando la reacción en cadena de la polimerasa en tiempo real (RT-PCR) como estándar de referencia. El algoritmo se entrenó y validó en 14,788 imágenes (4,253 COVID-19 positivas) de sitios en todo el Northwestern Memorial Healthcare System desde febrero de 2020 hasta abril de 2020, luego se probó en 2,214 imágenes (1,192 COVID-19 positivas) de una sola institución de reserva. **Resultados** Se evaluó a un total de 5.853 pacientes (58 ± 19 años, 3.101 mujeres) a través de conjuntos de datos. En todo el conjunto de pruebas, la precisión de DeepCOVID-XR fue del 83% con un AUC de 0,90.



En 300 imágenes de prueba aleatorias (134 COVID-19 positivas), la precisión de DeepCOVID-XR fue del 82% en comparación con los radiólogos individuales (76% - 81%) y el consenso de los 5 radiólogos (81%). DeepCOVID-XR tuvo una sensibilidad significativamente mayor (71%) que 1 radiólogo (60%, $p < 0,001$) y una mayor especificidad (92%) que 2 radiólogos (75%, $p < 0,001$; 84% $p = 0,009$). El AUC de DeepCOVID-XR fue de 0,88 en comparación con el AUC de consenso de 0,85 ($p = 0,13$ para la comparación). **Conclusión** DeepCOVID-XR, un algoritmo de IA detectó COVID-19 en radiografías de tórax con un rendimiento similar al consenso de radiólogos torácicos experimentados [15].

Lal Hussain, Tony Nguyen, Haifang Li, Adeel A. Abbasi, Kashif J. Lone, Zirun Zhao (Azad Kashmir - Pakistán, New York - EEUU, noviembre 2020) “**Machine-learning classification of texture features of portable chest X-ray accurately classifies COVID-19 lung infection**” que traducido al español es La clasificación de aprendizaje automático de las características de textura de la radiografía de tórax portátil clasifica con precisión la infección pulmonar por COVID-19. **Fondo** El gran volumen y la calidad de imagen subóptima de las radiografías de tórax portátiles como resultado de la pandemia de COVID-19 podrían representar desafíos importantes para los radiólogos y los médicos de primera línea. Los métodos de inteligencia artificial (IA) de aprendizaje profundo tienen el potencial de ayudar a mejorar la eficiencia y precisión del diagnóstico para leer radiografías portátiles. **Objetivo** El estudio tuvo como objetivo desarrollar una herramienta de análisis de imágenes de IA para clasificar la infección pulmonar COVID-19 basada en radiografías portátiles. **Materiales y métodos:** Se analizaron conjuntos de datos públicos de COVID-19 ($N = 130$), neumonía bacteriana ($N = 145$), neumonía viral no COVID-19 ($N = 145$) y radiografías normales ($N = 138$). Se extrajeron textura y características morfológicas. Se utilizaron cinco algoritmos de inteligencia artificial de



aprendizaje automático supervisados para clasificar COVID-19 de otras condiciones. Se realizaron clasificaciones de dos clases y de varias clases. El análisis estadístico se realizó utilizando pruebas t de dos colas no apareadas con varianza desigual entre los grupos. El rendimiento de los modelos de clasificación utilizó el análisis de la curva de características operativas del receptor (ROC). **Resultados** Para la clasificación de dos clases, la precisión, sensibilidad y especificidad fueron, respectivamente, 100%, 100% y 100% para COVID-19 frente a normal; 96,34%, 95,35% y 97,44% para COVID-19 frente a neumonía bacteriana; y 97,56%, 97,44% y 97,67% para la neumonía viral COVID-19 frente a la no COVID-19. Para la clasificación de clases múltiples, la precisión y el AUC combinados fueron 79,52% y 0,87, respectivamente. **Conclusiones** La clasificación de IA de la textura y las características morfológicas de las radiografías portátiles distingue con precisión la infección pulmonar por COVID-19 en pacientes en conjuntos de datos de clases múltiples. Los métodos de aprendizaje profundo tienen el potencial de mejorar la eficiencia y la precisión del diagnóstico de las radiografías portátiles [16].

Taresh, M., Zhu, N., Ali Ali, T. (Chang Sha - China, mayo 2021) **“Transfer learning to detect COVID-19 automatically from X-ray images, using convolutional neural networks.”** que traducido al español es aprendizaje por transferencia para detectar COVID-19 automáticamente a partir de imágenes de rayos X, utilizando redes neuronales convolucionales. Este estudio tiene como **objetivo** evaluar la efectividad de las redes neuronales convolucionales (CNN) preentrenadas de última generación en el diagnóstico automático de COVID-19 a partir de radiografías de tórax. El conjunto de datos utilizado en los experimentos consta de 1200 imágenes de radiografía de tórax de personas con COVID-19, 1345 imágenes de radiografía de tórax de personas con neumonía viral y 1341 imágenes de radiografía de tórax de personas sanas. **Método**, se exploró la efectividad de la inteligencia artificial (IA) en la identificación rápida y precisa de



COVID-19 a partir de imágenes de radiografía de tórax en función de diferentes algoritmos de aprendizaje profundo entrenados previamente y ajustados para maximizar la precisión de detección para identificar los mejores algoritmos. Los **resultados** mostraron que el aprendizaje profundo con imágenes de rayos X es útil para recopilar marcadores biológicos críticos asociados con las infecciones por COVID-19. VGG16 y MobileNet obtuvieron el mayor valor predictivo positivo del 98,28 %. Sin embargo, VGG16 superó a todos los demás modelos en la detección de COVID-19 con una exactitud, puntuación F1, valor predictivo positivo, especificidad y sensibilidad del 98,72 %, 97,59 %, 96,43 %, 98,70 % y 98,78 %, respectivamente. **Conclusiones**, El excelente rendimiento de estos modelos preentrenados puede mejorar significativamente la velocidad y la precisión del diagnóstico de COVID-19. Sin embargo, se requiere un conjunto de datos más grande de imágenes de rayos X de COVID-19 para una identificación más precisa y confiable de las infecciones por COVID-19 cuando se utiliza el aprendizaje de transferencia profunda[17].

Mohammadi R, Salehi M, Ghaffari H, Rohani AA, Reiazi R (Tehran - Irán, Toronto - Canadá, octubre 2020) “*Transfer Learning-Based Automatic Detection of Coronavirus Disease 2019 (COVID-19) from Chest X-ray Images*” que traducido al español es Aprendizaje por transferencia basado en detección automática de enfermedad por coronavirus 2019 (COVID-19) a partir de imágenes de rayos X de tórax. **Antecedentes:** la enfermedad por coronavirus 2019 (COVID-19) es una enfermedad infecciosa emergente y una crisis de salud global. Aunque la reacción en cadena de la polimerasa con transcripción inversa en tiempo real (RT-PCR) se conoce como el método de laboratorio más utilizado para detectar el COVID-19 en muestras respiratorias. Sufre de varios inconvenientes principales, como la gran cantidad de resultados falsos negativos que consumen mucho tiempo y la disponibilidad limitada. Por lo tanto, se requerirá la



detección automática de COVID-19. **Objetivo:** Este estudio tuvo como objetivo utilizar modelos de transferencia pre-entrenados basados en una red neuronal de convolución profunda automatizada para la detección de la infección por COVID-19 en radiografías de tórax. **Material y métodos:** En un estudio retrospectivo, hemos aplicado modelos pre-entrenados de Visual Geometry Group (VGG) -16, VGG-19, MobileNet e InceptionResNetV2 para la detección de la infección por COVID-19 a partir de 348 imágenes de rayos X de tórax. **Resultados:** Nuestros modelos propuestos han sido entrenados y probados en un conjunto de datos que se preparó previamente. Todos los modelos propuestos proporcionan una precisión superior al 90,0%. El modelo MobileNet previamente entrenado proporciona el rendimiento de clasificación más alto de la clasificación COVID-19 automatizada con una precisión del 99,1% en comparación con otros tres modelos propuestos. El área trazada bajo la curva (AUC) de las características operativas del receptor (ROC) de los modelos VGG16, VGG19, MobileNet e InceptionResNetV2 son 0.92, 0.91, 0.99 y 0.97, respectivamente. **Conclusión:** Todos los modelos propuestos pudieron realizar una clasificación binaria con una precisión de más del 90.0% para el diagnóstico de COVID-19. Nuestros datos indicaron que MobileNet puede considerarse como un modelo prometedor para detectar casos de COVID-19. En el futuro, al aumentar el número de muestras de radiografías de tórax COVID-19 en el conjunto de datos de entrenamiento, la precisión y solidez de nuestros modelos propuestos aumentan aún más [18].

Lin Li, Lixin Qin, Zeguo Xu , Youbing Yin , Xin Wang , Bin Kong, et.al. (Wuhan, Shenzhen, Liaocheng, Beijing - China, marzo 2020) “**Using Artificial Intelligence to Detect COVID-19 and Community-acquired Pneumonia Based on Pulmonary CT: Evaluation of the Diagnostic Accuracy**” que traducido al español es Uso de inteligencia artificial para detectar COVID-19 y neumonía adquirida en la comunidad basada en TC



pulmonar: evaluación de la precisión diagnóstica. **Objetivo** Desarrollar un marco completamente automático para detectar COVID-19 mediante TC de tórax y evaluar su rendimiento. **Materiales y métodos** En este estudio retrospectivo y multicéntrico, se desarrolló un modelo de aprendizaje profundo, la red neuronal de detección de COVID-19 (COVNet), para extraer características visuales de tomografías computarizadas volumétricas de tórax para la detección de COVID-19. Se incluyeron tomografías computarizadas de neumonía adquirida en la comunidad (NAC) y otras anomalías distintas de la neumonía para probar la solidez del modelo. Los conjuntos de datos se recopilaron de seis hospitales entre agosto de 2016 y febrero de 2020. El rendimiento diagnóstico se evaluó con el área bajo la curva característica operativa del receptor, la sensibilidad y la especificidad. **Resultados** El conjunto de datos recopilado consistió en 4352 tomografías computarizadas de tórax de 3322 pacientes. La edad promedio de los pacientes (\pm desviación estándar) fue de 49 años \pm 15, y hubo un poco más de hombres que de mujeres (1838 frente a 1484, respectivamente; $p = 0,29$). La sensibilidad y especificidad por exploración para detectar COVID-19 en el conjunto de pruebas independientes fue del 90% (intervalo de confianza [IC] del 95%: 83%, 94%; 114 de 127 exploraciones) y 96% (IC del 95%: 93%, 98%; 294 de 307 exploraciones), respectivamente, con un área bajo la curva característica de funcionamiento del receptor de 0,96 ($P < 0,001$). La sensibilidad y especificidad por exploración para detectar NAC en el conjunto de pruebas independientes fue del 87% (152 de 175 exploraciones) y del 92% (239 de 259 exploraciones), respectivamente, con un área bajo la curva característica de funcionamiento del receptor de 0,95 (95% CI: 0,93, 0,97). **Conclusión** Un modelo de aprendizaje profundo puede detectar con precisión el coronavirus 2019 y diferenciarlo de la neumonía adquirida en la comunidad y otras afecciones pulmonares [19].



Valencia, C. Serrano, X. (CDMX - México, 2021) **Determinación de COVID -19 por TCAR: estimación diagnóstica médica vs sistema de inteligencia artificial. Objetivos** establecer la concordancia entre la estimación diagnóstica médica vs el sistema de IA para el diagnóstico de COVID-19. **Material y métodos** se realizó un estudio de tipo observacional, descriptivo, retrospectivo y transversal en el servicio de Tomografía del Hospital General “Gaudencio González Garza” del Centro Médico Nacional La Raza, Hospital General de Zona #48 “San Pedro Xalpa” y el Hospital General de Zona #1, "Dr. Ignacio García Téllez" delegación San Luis Potosí. Se recopiló los estudios de tomografías de tórax de alta resolución de pacientes con diagnóstico de sospecha de neumonía en el periodo del 10 marzo de 2020 al 09 de junio de 2020; después se seleccionó una muestra de tomografías de pacientes que fueron solicitadas durante ese periodo al hospital. El sistema de inteligencia artificial CviCom UNAM COVID-19 que se usó se desarrolló en colaboración entre el centro virtual de computación (CviCom) del UNAM, el laboratorio de procesamiento de imágenes (Lapi) de la Facultad de Ingeniería de la UNAM y el servicio de imagen del Hospital General del Centro Médico Nacional la Raza, el cual fue comparado con el rendimiento diagnóstico de 3 radiólogos expertos en el área de tomografía y un residente de tercer y cuarto año de Imagenología diagnóstica y terapéutica, se realizaron medidas estadísticas, para determinar la sensibilidad, especificidad y exactitud y compararla con las mismas medidas en el sistema de inteligencia artificial, posteriormente se confeccionó una curva ROC, para determinar la utilidad del sistema inteligencia artificial como prueba diagnóstica. Recursos e Infraestructura: Base de datos del servicio de Tomografía del departamento de Radiología e Imagen. **Resultados** El sistema de Inteligencia artificial logró una exactitud de prueba del 96%, una sensibilidad del 95.9% (IC del 95%: 92.9%-100%) y una especificidad del 98.0% (IC del 95%: .94.9-100%) con área bajo la curva característica de funcionamiento



del receptor de 0,970 lo que nos indica que funciona muy bien como prueba diagnóstica. Al comparar los resultados del sistema de inteligencia artificial con cada uno de los radiólogos se observó un coeficiente kappa mayor a 0.6 (0.758-0.854) lo que nos indica una concordancia de buena a excelente interobservador, con un grado de confianza <0.005 . **Conclusiones** El sistema de inteligencia artificial CVICOM-COVID-19 tuvo unos resultados de sensibilidad, especificidad y precisión altos para el diagnóstico de COVID-19 en imágenes de tomografía (95,9, 98.0 y 96% respectivamente), al compararse con radiólogos expertos, su rendimiento no fue inferior y sus resultados se obtienen en cuestión de segundos, el área bajo la curva, fue 0.970 la cual nos indica que funciona adecuadamente como prueba diagnóstica, fue evaluado con imágenes de distintos hospitales y distintos tomógrafos y cuenta con una validación externa adecuada. Este estudio es el primero en Latinoamérica de diagnóstico de COVID- 19 mediante inteligencia artificial en imágenes tomografía, los resultados son similares a otros publicados en la literatura sin embargo por la estructura del sistema y la facilidad de este permitiría su uso de forma generalizada en varios hospitales de la República Mexicana e incluso otros países [20].

2.1.2 Antecedentes nacionales, regionales y locales

A la fecha de realización de este trabajo no existen antecedentes nacionales, regionales o locales.

2.2 Bases Teóricas

2.2.1 COVID-19

Generalidades

Los coronavirus pertenecen a una familia de virus ARN de gran variedad que afectan tanto humanos como animales. A finales de 2019 se identificó un nuevo coronavirus en



Wuhan – China debido a ser causante de una neumonía viral inexplicable, hoy nombrado coronavirus 2 del síndrome respiratorio agudo severo SARS- COV-2 [21]. Este brote se extendió rápidamente por china, y posteriormente por otros 19 países, siendo así el 30 de enero de 2020 declarada una emergencia de salud pública de interés internacional [22]. Durante el mes de febrero de 2020, la Organización Mundial de la Salud designó la enfermedad COVID-19, que significa enfermedad por coronavirus 2019 [23].

Virología

Según la filogenia, taxonomía y clínica que produce, se ha establecido SARS-COV-2 es un virus ARN de hebra positiva típica de la familia Coronaviridae y género Betacoronavirus relacionado con el síndrome respiratorio agudo severo [11]. SARS-COV-2 se diferencia de otros dos coronavirus de origen zoonótico como SARS-CoV y MERS-CoV por su hospedador intermediario que logra la transmisión humana, aunque es muy similar la región del gen de unión al receptor del coronavirus SARS y que el virus usa el mismo receptor, la enzima convertidora de angiotensina 2 (ACE2), para su ingreso dentro de la célula [24,25].

Epidemiología

A nivel mundial se encuentran hasta la fecha (21 de Mar. de 21) un total de 12 3074 318 de COVID-19, siendo propios de Perú 1 460 779, y específicos del departamento de Cusco 40 343. Según la sala situacional COVID 2021 contamos con 23191 casos en total durante 2021, siendo la provincia más afectada Cusco con 11697 casos en total, seguida por la convención con 3 942 casos en total. [26,27]

Transmisibilidad

La transmisibilidad del virus es principalmente por contacto con las gotitas respiratorias. La transmisión directa que se produce por contacto a menos de un metro con una persona



con síntomas respiratorios debido a la facilidad de que las mucosas y la conjuntiva entran en contacto con gotitas respiratorias que pueden ser infecciosas [28]. La transmisión indirecta se produce cuando una persona entra en contacto con superficies a través de fómites, de igual modo al entrar en contacto con objetos utilizados por el enfermo como termómetro y estetoscopio. La transmisión aérea es secundaria a procedimientos o tratamientos que generen aerosoles como intubación endotraqueal, broncoscopias, ventilación no invasiva con presión positiva [28].

Factores de riesgo para enfermedad severa

Caracterizada por dificultad respiratoria severa y necesidad de oxígeno suplementario para el paciente puede estar presente a cualquier edad, sin embargo, es mayor la frecuencia en adultos mayores o personas que padecen comorbilidades médicas subyacentes [29]. entre los factores de riesgo para hacer enfermedad grave destaca la edad mayor de 75 años que también se asocia a mayor riesgo de muerte, también se considera el sexo masculino y ser obeso (IMC >40). El incremento del riesgo para enfermedad severa también se relaciona con la presencia de enfermedades preexistentes, principalmente hipertensión arterial, diabetes, cáncer activo y enfermedad renal crónica, siendo el de mayor asociación el padecer cáncer activo. [21]

Las características particulares de laboratorio también se han asociado con peores resultados [30]:

- Linfopenia
- Plaquetopenia
- Elevación de enzimas hepáticas (ALT, AST)
- Elevación de lactato deshidrogenasa (LDH)
- Elevación de la creatinina



- Dímero D elevado (> 1 mcg / MI)



Manifestaciones Clínicas.

Las manifestaciones clínicas son variadas y poco específicas, sin embargo, entre toda la gama de signos y síntomas que pueden estar presentar, la anosmia y la ageusia son las que cuentan con una especificidad más alta. El paciente puede presentar en general síntomas gripales como fiebre, fatiga, tos seca, anorexia y mialgias presentadas en orden de mayor a menor frecuencia [29]. Cabe resaltar que la presencia de clínica no es únicamente respiratoria, a pesar de que esta sea la más frecuente, como es la clínica cardiovascular, gastrointestinal e incluso neurológica. [31]

Curso y Complicaciones

El curso de los pacientes con COVID 19 es muy variable, presentándose desde pacientes asintomáticos, a sintomáticos leves 81% aproximadamente; sintomáticos graves 14% que cursan con disnea e hipoxia o afectación pulmonar mayor al 50% demostrado por imagen y críticos 5% que presentan insuficiencia respiratoria, shock o falla multiorgánica [32]. Entre todo esto es importante identificar lo más precozmente a los que poseen manifestaciones clínicas graves para que reciban un manejo oportuno en el centro de salud más adecuado, se encontrarán en este grupo pacientes que cursen con neumonía y además saturación periférica de oxígeno menor de 90% o frecuencia respiratoria mayor a 29 respiraciones por minuto. [33]

El periodo promedio de incubación es de 5.68 días aproximadamente. La duración de los síntomas es de 18.55 días y existe un retraso de 4.92 días desde el inicio de los síntomas hasta la primera visita clínica [34]. En el caso de los pacientes graves que presentaron síndrome de distrés respiratorio agudo (SDRA) que ingresaron a hospitalización y fallecieron, existió un periodo de 17.5 días en promedio desde el ingreso hasta el día de deceso [35].



Los resultados clínicos al ser variables también coinciden con una variedad de complicaciones, predominando las complicaciones respiratorias sobre todo el SDRA, entre las complicaciones no respiratorias destacan la lesión cardíaca aguda y la insuficiencia renal aguda (IRA) [36]. Dentro de los casos clínicos se considera a quienes recibieron ventilación mecánica, atención en UCI o cursaron con síntomas de shock o atendidos en un hospital de atención terciaria, siendo 70% de los casos varones y 30% mujeres [37].

Hallazgos en Imágenes

Se utiliza ampliamente la radiografía de tórax y la tomografía computarizada de tórax para el diagnóstico de COVID-19 [34,35].

Radiografía de Tórax

Generalmente es visible afectación bilateral, sin embargo, existen pacientes sin anomalías en la radiografía de tórax especialmente al inicio de la enfermedad. Entre los hallazgos radiográficos más comunes tenemos patrón reticular, consolidaciones y patrón en vidrio deslustrado, que típicamente tienen una distribución bilateral, subpleural y periférica, predominando en los campos inferiores; estos hallazgos pueden evolucionar a enfermedad difusa en el transcurso de la primera a la tercera semana desde el inicio de los síntomas [32,34].

Estas anomalías pueden persistir hasta las 12 semanas tras el alta en un 36% de pacientes y hasta 6 meses posterior al alta en 30% [38].

Tomografía

Se pueden apreciar la presencia de dilataciones bronquiales, bandas subpleurales, afectación intersticial subpleural de forma no panal y patrón de vidrio deslustrado con



mayor frecuencia; otras presentaciones menos comunes con el atrapamiento aéreo, neumatoceles y la presentación en panal. Es importante resaltar que la distribución suele ser bilateral, periférica y a predominio de los campos inferiores.[38]

Diagnóstico

Diagnóstico clínico: se incluyen a todos los casos con síndrome gripal con antecedente de viaje al interior o exterior del país, o contacto cercano con personas que hayan realizado dichas actividades en los último 14 días.

Diagnóstico laboratorial:

Pruebas serológicas

La muestra se obtiene por punción de la yema de los dedos con el fin de extraer una gota de sangre, que será colocada en la prueba rápida para la detección de IgG o IgM desarrollado frente a SARS-CoV-2.[39]

La interpretación de resultados es [39]:

Reactivo IgM: infección reciente, se visualiza banda de control y banda IgM.

Reactivo IgG: infección pasada, se visualiza banda de control y banda IgG.

Reactivos IgM e IgG: infección en curso, se visualizan las tres bandas IgG, IgM y control.

No reactivo: se visualiza sólo la banda de control, indica que no hay una cantidad de inmunoglobulina detectable.

Inválido: ausencia de banda de control a pesar de presencia de cualquiera de las otras bandas.



Prueba molecular

Se realiza a través de la identificación del virus SARS-CoV-2 por técnica de Reacción en Cadena de la Polimerasa en tiempo real (RT-PCR), mediante el secuenciamiento parcial o total del genoma del virus [5].

La muestra se obtiene por hisopado nasal y faríngeo, lavado bronco alveolar, aspirado traqueal, nasal o faríngeo, esta prueba está dirigida para aquellos que cumplan con la definición de caso sospechoso [4]. El resultado positivo es muy específico para el diagnóstico de SARS-Cov-2. Es considerado el estándar de oro, aunque la sensibilidad de esta prueba se ve afectada por el límite en la detección, es decir, está sujeta a la cantidad de inóculo viral al momento de la prueba y del sitio de recolección de muestra, considerando que la toma de muestra antes de los tres días de los síntomas o después del séptimo día puede dar como resultado falsos negativos, resultado tener una sensibilidad aproximada del 70% y una especificidad de 95% [40].

Prueba de Antígeno

Son pruebas diseñadas para la detección de un segmento conformante del SARS-CoV-2, el antígeno, tiene la ventaja de brindar un resultado en cuestión de minutos. Entre sus desventajas suelen ser menos sensibles que la prueba de RT-PCR y puede verse afectada por la temporalidad de la toma de muestra[41]. Sin embargo, pueden ser útiles en determinadas situaciones, siempre que los médicos sean conscientes de la posibilidad de falsos negativos y los resultados se interpreten en función de la probabilidad previa a la prueba de COVID-19[42].

Definiciones de Casos COVID-19 [4,39]:

- Caso sospechoso de COVID 19: Persona que cumpla con cualquiera de los siguientes criterios clínicos.



a. Paciente con síntomas de infección respiratoria aguda, que presente tos y/o dolor de garganta y además uno o más de los siguientes signos / síntomas:

- Malestar general
- Fiebre
- Cefalea
- Congestión nasal
- Diarrea
- Dificultad para respirar (señal de alarma)
- Pérdida del olfato (anosmia)
- Pérdida del gusto (ageusia)

b. Paciente con infección respiratoria aguda grave (IRAG: infección respiratoria aguda con fiebre o temperatura actual $\geq 38^{\circ}\text{C}$; y tos; con inicio dentro de los últimos 10 días; y que requiere hospitalización).

▪ Caso probable de COVID 19: Quienes cumplan con cualquiera de los siguientes criterios:

a. Caso sospechoso con antecedente epidemiológico de contacto directo con un caso probable o confirmado, o epidemiológicamente relacionado a un conglomerado de casos los cuales han tenido al menos un caso confirmado dentro de ese conglomerado 14 días previos al inicio de los síntomas.

b. Caso sospechoso con imágenes de tórax que muestran hallazgos radiológicos sugestivos de COVID-19, en:



- Radiografía de tórax: opacidades nebulosas, de morfología a menudo redondeadas, con distribución pulmonar periférica e inferior.
 - Tomografía computarizada de tórax: múltiples opacidades bilaterales en vidrio esmerilado, a menudo de morfología redondeada, con distribución pulmonar periférica e inferior.
 - Ecografía pulmonar: líneas pleurales engrosadas, líneas B (multifocales, aisladas o confluentes), patrones de consolidación con o sin broncogramas aéreos.
- c. Persona con inicio reciente de anosmia (pérdida del olfato) o ageusia (pérdida del gusto), en ausencia de cualquier otra causa identificada.
- Caso confirmado de COVID 19: Quienes cumplan con cualquiera de los siguientes criterios:
 - a. Caso sospechoso o probable con confirmación de laboratorio de infección por COVID-19, mediante prueba molecular para SARS-CoV-2 positiva
 - b. Caso sospechoso o probable con prueba antigénica positiva para infección por SARS-CoV-2.
 - c. Caso sospechoso o probable con prueba serológica (ELISA, Inmunofluorescencia, quimioluminiscencia y electroquimioluminiscencia) reactiva a IgM o IgM/IgG para infección por SARS-CoV-2.
 - Caso descartado: paciente que cuenta con resultados de laboratorio negativos para COVID-19.



Clasificación y lugar de manejo [4]:

- Caso leve: requiere aislamiento domiciliario. todo paciente con infección respiratoria aguda que presenta al menos dos de los siguientes síntomas:
 - Tos
 - Malestar general
 - Dolor de garganta
 - Fiebre
 - Congestión nasal

- Caso moderado: requiere hospitalización, es todo paciente con infección respiratoria aguda que cumple alguno de los siguientes criterios:
 - Disnea o dificultad respiratoria
 - Frecuencia respiratoria > 22 respiraciones por minuto
 - Saturación de oxígeno $< 95\%$
 - Alteración de conciencia (presencia de confusión o desorientación)
 - Hipotensión arterial o shock
 - Signos clínicos y/o radiológicos de neumonía
 - Recuento linfocitario de 1000 células/ μL

- Caso severo: requiere hospitalización y manejo en área de cuidados críticos, es toda persona con infección respiratoria aguda con dos o más de los siguientes criterios:
 - Frecuencia respiratoria > 22 respiraciones por minuto o $\text{PaCO}_2 < 32\text{mmHg}$
 - Alteración del nivel de conciencia
 - Presión arterial sistólica menor a 100 mmHg o $\text{PAM} < 65\text{mmHg}$
 - $\text{PaO}_2 < 60$ mmHg o $\text{PaFi} < 300$



- Signos clínicos de fatiga muscular: aleteo nasal, uso de músculos accesorios, desbalance toraco abdominal.
- Lactato sérico $> 2\text{mOsm/L}$

2.2.2 Inteligencia Artificial

La inteligencia artificial se puede definir como la inteligencia que es demostrada por las máquinas a diferencia de la inteligencia natural demostrada por los seres humanos, que involucra emociones y conciencia [43].

Se estudia como subdisciplina de las ciencias de la computación definiendo como inteligencia artificial a “cualquier dispositivo que perciba su entorno y tome acciones que maximicen sus posibilidades de lograr con éxito sus objetivos” [44].

La inteligencia artificial a menudo gira en torno al uso de algoritmos. Un algoritmo es un conjunto de instrucciones inequívocas que puede ejecutar una computadora mecánica, a su vez un algoritmo complejo a menudo se construye sobre otros algoritmos más simples [45]. Muchos algoritmos de IA son capaces de aprender de los datos; pueden mejorarse aprendiendo nuevas heurísticas (estrategias o "reglas generales" que han funcionado bien en el pasado).

Aprendizaje Automático

El aprendizaje automático, traducción del anglicismo “machine learning” se define como el estudio de algoritmos informáticos que mejoran automáticamente a través de la experiencia y mediante el uso de datos [46]. Se la considera un subcampo de la inteligencia artificial.

El aprendizaje automático implica que las computadoras descubran cómo pueden realizar tareas sin estar programadas explícitamente para hacerlo. Se trata de que las computadoras aprendan de los datos proporcionados para llevar a cabo determinadas



tareas. Para tareas simples asignadas a computadoras, es posible programar algoritmos que le digan a la máquina cómo ejecutar todos los pasos necesarios para resolver el problema en cuestión; por parte de la computadora, no se necesita aprendizaje. Para tareas más avanzadas, puede ser un desafío para un ser humano crear manualmente los algoritmos necesarios. En la práctica, puede resultar más eficaz ayudar a la máquina a desarrollar su propio algoritmo, en lugar de que los programadores humanos especifiquen cada paso necesario [47].

Aprendizaje Automático Supervisado

También llamado aprendizaje de representación es un tipo de aprendizaje automático en el que el algoritmo aprende por sí solo las mejores características para clasificar los datos proporcionados. A la computadora se presenta con datos de entrada y sus respectivos datos de salida proporcionados por una persona, el objetivo de la computadora será aprender una regla general que relaciona los datos de entrada con los datos de salida clasificándolos, es esta regla que obtiene la computadora la que usa para clasificar nuevos datos de entrada en los datos de salida [48,49].

Aprendizaje Profundo (Deep Learning)

El aprendizaje profundo es un tipo de aprendizaje de representación en el que el algoritmo usa redes neuronales artificiales con numerosas capas ocultas, también llamadas capas intermedias, que se encuentran entre la capa de entrada y la capa de salida, de esta manera se desarrolla una extensa estructura interna. Este tipo de estructura permite que el algoritmo extraer progresivamente características de los datos de entrada [50].

Como se grafica en la Figura 1. Cada capa está constituida de varias “neuronas” y cada neurona representa una función matemática que es aplicado a los datos de entrada, de esta



manera el algoritmo extrae información de los datos de entrada, por esta razón este tipo de aprendizaje automático se le denomina minería de datos [51].

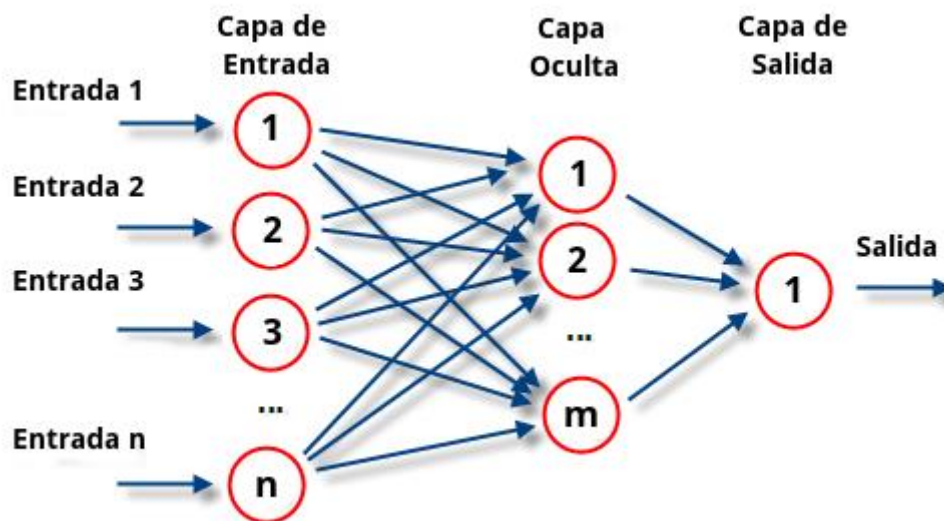


Figura 1. Esquema de una red neuronal artificial.

Donde en la capa de entrada hay “n” neuronas de entrada, en la capa oculta hay “m” neuronas y en la capa de salida hay una sola neurona. Imagen extraída de <https://commons.wikimedia.org/> con licencia de libre uso de Creative Commons.

La mayoría de los modelos modernos de aprendizaje profundo se basan en redes neuronales artificiales, específicamente redes neuronales convolucionales [52].

Redes Neuronales Convolucionales

Son una clase de redes neuronales artificiales, en la que la red neuronal artificial emplea una operación matemática llamada convolución, que será desarrollada por las capas intermedias. Son comúnmente aplicadas para analizar imágenes visuales [53].



Aplicaciones clínicas del aprendizaje Automático

El aprendizaje profundo aplicado a las imágenes médica es una realidad, demostrando resultados prometedores en diagnósticos complejos en diferentes ramas como dermatología, radiología, oftalmología y patología [54]

El desarrollo actual de la inteligencia artificial tiene un rendimiento diagnóstico comparable al de los expertos médicos, especialmente en los campos relacionados con el reconocimiento de imágenes [55]. También pueden ayudar de manera predictiva, pronosticando el tiempo hasta el deterioro o mejora clínica [56].

Uno de los usos más investigados del machine learning en medicina es la clasificación, donde el algoritmo de inteligencia artificial debe de clasificar imágenes, como, por ejemplo, benignidad o malignidad en una fotografía de piel, la presencia o no de una enfermedad a partir de una imagen de radiografía, entre otros. Para esta tarea se necesita entrenar al algoritmo con un conjunto de imágenes previamente clasificadas, además, para que el algoritmo sea más preciso se necesita un gran número de estas imágenes, lo que puede resultar en una desventaja, ya que es difícil construir un conjunto de imágenes, clasificarlas y que éste sea de un número suficiente para que el algoritmo sea preciso. Afortunadamente en la actualidad, gracias al internet y la globalización, se cuentan con proyectos que reúnen estos conjuntos de datos que están con libre acceso para cualquier persona que desee desarrollar un algoritmo [57,58].

Métricas de evaluación.

El rendimiento de los algoritmos se evalúa utilizando la precisión, que es la proporción de datos predichas correctamente sobre el total de las predicciones. Para la evaluación de un algoritmo de inteligencia artificial como prueba diagnóstica se puede realizar una matriz de confusión, donde se pueden comparar el porcentaje de datos etiquetados



correcta e incorrectamente, pudiendo calcular así su sensibilidad, especificidad, valor predictivo positivo y valor predictivo negativo [20].

2.2.3 Radiografía de tórax como método de detección de COVID-19

La radiografía de tórax se ha utilizado como método de detección alternativo para la COVID-19, en el que los radiólogos realizan y analizan imágenes de radiografía de tórax (p. Ej., Radiografía de tórax o tomografía axial computarizada) para buscar indicadores visuales asociados con la infección viral SARS-CoV-2 [59]. En los primeros estudios se encontró que los pacientes presentan anormalidades en las imágenes de la radiografía de tórax que son características de los infectados con COVID-19, y se ha demostrado que la radiología en tórax es una herramienta fundamental en la detección precoz de la enfermedad en zonas epidémicas [60].

La radiografía de tórax tiene ciertas ventajas que la hacen útil en zonas que no tienen recursos y están muy afectadas:

Las radiografías de tórax para la clasificación rápida permiten una clasificación temprana de los pacientes con sospecha de COVID-19 y se pueden realizar en paralelo a las pruebas virales (lo que lleva un tiempo) para ayudar a aliviar las grandes cantidades de pacientes, especialmente en las áreas más afectadas donde se han agotado las pruebas de detección viral, o incluso de forma independiente cuando las pruebas virales no son una opción (zonas pobres). Además, las imágenes de radiografía de tórax pueden ser bastante efectivas para clasificar a los pacientes en áreas geográficas donde se indica a los pacientes que se queden en casa hasta la aparición de síntomas avanzados, ya que a menudo se observan anomalías en las imágenes de tórax cuando los pacientes deciden a un sitio de atención clínica [61].



Disponibilidad y accesibilidad. Las radiografías de tórax están fácilmente disponibles y accesibles en muchos sitios clínicos y centros de imágenes, ya que se consideran equipos estándar en la mayoría de los sistemas de salud [11]. En particular, Las radiografías de tórax están mucho más disponibles que las imágenes por tomografía computarizada, especialmente en nuestro país donde los escáneres de tomografía computarizada mayormente se encuentran disponibles en el tercer nivel de atención (en muchas ocasiones centralizadas en las capitales de los departamentos) o en clínicas privadas donde el precio es una limitación prohibitiva para los pacientes.

Portabilidad. La existencia de sistemas de radiografía portátiles significa que las imágenes se pueden realizar las tomas de imágenes dentro de una sala de aislamiento, lo que reduce significativamente el riesgo de transmisión de COVID-19 durante el transporte a sistemas fijos como escáneres de tomografía computarizada [61].

2.3 Definición de términos básicos

- Inteligencia artificial: Es la combinación de cálculos planteados con el propósito de crear máquinas que presenten capacidades similares al ser humano.
- Aprendizaje Automático: Es el proceso por el cual los ordenadores desarrollan el reconocimiento de patrones o la capacidad de aprender continuamente y hacer predicciones basadas en datos, tras lo cual realizan ajustes sin haber sido programados específicamente para ello.
- Aprendizaje Automático supervisado: Es una técnica para deducir una función a partir de datos de entrenamiento.
- Modelo de Aprendizaje Automático: Es el conjunto de operaciones que son resultado del aprendizaje automático no supervisado.
- COVID-19: Enfermedad causada por el agente viral SARS-CoV-2
- SARS-CoV-2: nuevo coronavirus que es el agente causal de COVID-19



- RT-PCR para SARS-CoV2: Retro- transcriptasa reversa, prueba laboratorial estándar de oro para el diagnóstico de COVID-19.
- Caso Sospechoso: persona con clínica respiratoria reciente que viajó o vive en una zona de transmisión local, que tuvo contacto con un caso probable o confirmado de SARS-CoV-2 durante los últimos 14 días o que cumple con criterios de gravedad sin otra etiología que explique el cuadro.
- Caso probable: un caso sospechoso con resultado de laboratorio indeterminado para COVID-19.
- Caso Confirmado: Persona con prueba laboratorial positiva para infección de COVID-19, independientemente de su clínica.
- Radiografía de Tórax: Prueba de imagen que por uso de rayos permite visualizar órganos internos de la caja torácica como corazón y pulmones.
- Sensibilidad: Relación entre los verdaderos positivos y la suma de los verdaderos positivos y los falsos negativos
- Especificidad: Relación entre los verdaderos negativos y la suma de los verdaderos negativos y los falsos positivos
- Valor Predictivo Positivo: Relación entre los verdaderos positivos y la suma de los verdaderos positivos y los falsos positivos
- Valor Predictivo Negativo: Relación entre los verdaderos negativos y la suma de los falsos negativos y los verdaderos negativos
- Precisión: Es la relación entra la suma de los verdaderos positivos más los verdaderos negativos y todos los sujetos de estudio

2.4 Hipótesis

Hipótesis General: La inteligencia artificial para el diagnóstico de COVID 19, presenta una alta sensibilidad y especificidad.



Hipótesis Específicas:

La inteligencia artificial para el diagnóstico de COVID 19 presenta un alto valor predictivo positivo.

La inteligencia artificial para el diagnóstico de COVID 19 presenta un alto valor predictivo negativo.

La inteligencia artificial para el diagnóstico de COVID 19 presenta una alta precisión.



2.5 Variables

2.5.1 Identificación de Variables

Sensibilidad: Es la relación entre los verdaderos positivos y la suma de los verdaderos positivos y los falsos negativos. Es la probabilidad de clasificar correctamente a un individuo enfermo. La capacidad de la prueba para detectar la enfermedad

Especificidad: Es relación entre los verdaderos negativos y la suma de los verdaderos negativos y los falsos positivos. Es la probabilidad de clasificar correctamente a un individuo sano. La probabilidad de que para un sujeto sano se obtenga un resultado negativo. La capacidad para detectar a los sanos.

Valor Predictivo Positivo: Es relación entre los verdaderos positivos y la suma de los verdaderos positivos y los falsos positivos. Es la probabilidad de padecer la enfermedad si se obtiene un resultado positivo en la prueba.

Valor Predictivo Negativo: Es la relación entre los verdaderos positivos y la suma de los verdaderos positivos y los falsos positivos. Es la probabilidad de que un sujeto con un resultado negativo en la prueba esté realmente sano.

Precisión: Es la relación entra la suma de los verdaderos positivos más los verdaderos negativos y todos los sujetos de estudio. Es la probabilidad de que el resultado de la prueba sea correcto.



2.5.2 Operacionalización de variables

Variable	Definición Conceptual	Dimensiones	Tipo de Variable	Naturaleza	Escala de Medición	Indicador	Fuente de información	Definición operacional
Verdaderos positivos	Individuos enfermos que resultaron positivo a la prueba diagnóstica	Unidimensional	Independiente	Cuantitativa	Discreta	Tabla de Confusión	Inventario de Datos	Valor numérico
Falsos positivos	Individuos sanos que resultaron positivo a la prueba diagnóstica	Unidimensional	Independiente	Cuantitativa	Discreta	Tabla de Confusión	Inventario de Datos	Valor numérico
Falsos negativos	Individuos enfermos que resultaron negativo a la prueba diagnóstica	Unidimensional	Independiente	Cuantitativa	Discreta	Tabla de Confusión	Inventario de Datos	Valor numérico
Verdaderos negativos	Individuos sanos que resultaron negativo a la prueba diagnóstica	Unidimensional	Independiente	Cuantitativa	Discreta	Tabla de Confusión	Inventario de Datos	Valor numérico
Sensibilidad	Relación entre los verdaderos positivos y la suma de los verdaderos positivos y los falsos negativos	Verdaderos positivos y falsos negativos	Dependiente	Cuantitativa	Continua	Tabla de Confusión	Inventario de Datos	Porcentaje
Especificidad	Relación entre los verdaderos negativos y la suma de los verdaderos negativos y los falsos positivos	Verdaderos negativos y falsos positivos	Dependiente	Cuantitativa	Continua	Tabla de Confusión	Inventario de Datos	Porcentaje



Valor Predictivo Positivo	Relación entre los verdaderos positivos y la suma de los verdaderos positivos y los falsos positivos	Verdaderos positivos y falsos positivos	Dependiente	Cuantitativa	Continua	Tabla de Confusión	Inventario de Datos	Porcentaje
Valor Predictivo Negativo	Relación entre los verdaderos negativos y la suma de los falsos negativos y los verdaderos negativos	Verdaderos negativos y falsos negativos	Dependiente	Cuantitativa	Continua	Tabla de Confusión	Inventario de Datos	Porcentaje
Precisión	Es la relación entre la suma de los verdaderos positivos más los verdaderos negativos y todos los sujetos de estudio	Verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos	Dependiente	Cuantitativa	Continua	Tabla de Confusión	Inventario de Datos	Porcentaje



CAPITULO III: MÉTODO

3.1 Alcance del estudio

Se realizó en el Hospital Adolfo Guevara Velazco, Hospital Regional del Cusco y Hospital Antonio Lorena, con la información obtenida desde 01 de enero 2018 hasta 31 de diciembre del año 2021.

3.2 Tipo de investigación

El diseño fue de tipo no experimental, observacional porque no se realizó manipulación de variables

Transversal porque se ejecutó la recolección de datos a través de observación en un solo punto en el tiempo.

Retrospectivo porque la recolección de datos a partir de un evento que sucedió en el pasado.

3.3 Diseño de investigación

Descriptivo porque se midieron las variables en el estudio.

Prueba diagnóstica porque se midió el rendimiento de una nueva prueba frente a la prueba de oro.

3.4 Población y muestra

3.4.1 Descripción de la población

La población de estudio para el grupo “con la enfermedad” fueron todos los casos confirmados por RT-PCR o prueba antigénica y una radiografía de tórax durante la enfermedad de COVID 19 periodo 2020-2021; la población de estudio para el grupo “sin la enfermedad” fueron todos los pacientes que contaban con una radiografía de tórax en



el periodo 2018-2019; ambos grupos del Hospital Nacional Adolfo Guevara Velasco, Hospital Regional del Cusco y Hospital Antonio Lorena.

3.4.2 Criterios inclusión y exclusión

Para el Paciente “Con la enfermedad”

Criterios de inclusión:

- Paciente con historia clínica.
- Paciente con sintomatología de COVID 19
- Pacientes que cuente con RT PCR o prueba antigénica para COVID 19
- Presentar radiografía de tórax durante el periodo sintomático.
- Ser mayor de edad.

Criterios de exclusión:

- Paciente asintomático para COVID 19.
- Paciente que no cuente con RT PCR o prueba antigénica para COVID 19
- Paciente sin radiografía de tórax durante el periodo sintomático
- Ser menor de edad.
- Paciente con otra patología respiratoria no asociada a la infección por SARS-CoV2

Para el Paciente “Sin la enfermedad”

Criterios de inclusión:

- Paciente con radiografía de tórax tomada antes del 31/12/2019
- Paciente con historia clínica
- Paciente mayor de edad



Criterios de exclusión:

- Paciente con radiografía tomada después del 31/12/2019
- Paciente sin historia clínica
- Paciente menor de edad

3.4.3 Muestra: tamaño y métodos de muestreo

Para calcular el tamaño de muestra para prueba diagnóstica se utilizó el método de Obuchowski [62], calculada por el paquete estadístico Epidat en su versión 4.2, con los siguientes datos: Sensibilidad esperada de 90% (basado en el estudio piloto, véase Anexo 3), razón de no enfermos a enfermos de 2, nivel de confianza de 95% y una precisión absoluta de 3%. Con los siguientes resultados:

[1] Tamaños de muestra. Pruebas diagnósticas:

Datos:

Sensibilidad esperada:	90,000%
Razón no enfermos/enfermos:	2,00
Nivel de confianza:	95,0%

Resultados:

Precisión (%)	Tamaño de la muestra		
	Enfermos	No enfermos	Total
3,000	385	770	1.155
5,000	139	278	417

Tamaño de muestra total = 1155

- Con la enfermedad = 385



- Sin la enfermedad = 770

El método de muestreo seleccionado fue no probabilístico de tipo consecutivo para el grupo “con la enfermedad” y el grupo “sin la enfermedad”.

3.5 Técnicas, instrumentos y procedimientos de recolección de datos

Técnica de recolección de datos:

Se utilizó la técnica observacional sin intervención de los investigadores, haciendo una recolección de datos de forma sistematizada de historias clínicas, del departamento de estadística y radiología para la búsqueda del grupo “con la enfermedad” y sólo del departamento de radiología para la búsqueda del grupo “sin la enfermedad”.

Los datos referentes a las variables principales fueron obtenidos de una fuente secundaria, debido a que no se empleó una técnica de entrevista directa, por consiguiente, no fue necesario el uso de consentimiento informado.

Primero se realizó la búsqueda del grupo “con la enfermedad” del área de estadística de los hospitales, luego se hizo la búsqueda en los departamentos de radiología para extraer las radiografías de tórax pertenecientes al periodo 2020-2021, conociendo así la totalidad de pacientes que cuentan con la misma. Se realizó la aplicación de los criterios de inclusión y exclusión para la selección de la muestra, empleando un muestreo no probabilístico de tipo consecutivo, para obtener una muestra de 385 radiografías.

Segundo se procedió a la búsqueda del grupo “sin la enfermedad” en el área de radiología de los hospitales, luego la extracción de radiografías de tórax pertenecientes al periodo 2018-2019, conociendo así la totalidad de pacientes que contaban con las misma. Se realizó la aplicación de criterios de inclusión y exclusión para la selección de la muestra,



empleando un muestreo no probabilístico de tipo consecutivo, para obtener una muestra de 770 radiografías.

Una vez obtenido el total de pacientes considerados para la investigación mediante la aplicación de los criterios, se procedió a recolectar principalmente las radiografías de tórax.

Seguidamente se adjuntó y clasificó estas radiografías en un inventario donde almacenó las 1150 radiografías, clasificándolas en 2 grupos, 385 de “Con la Enfermedad” y 770 de “Sin la Enfermedad”.

Se agregó el resultado proporcionado por el modelo de inteligencia artificial con las etiquetas resultantes.

Se confeccionó una Tabla de Confusión para calcular nuestras variables.

3.6 Plan de análisis de datos

3.6.1 Técnicas estadísticas para la recolección de datos.

De acuerdo con las recomendaciones del Ministerio de salud se desarrollará la tabla de confusión para hallar sensibilidad, especificidad, valor predictivo positivo, valor predictivo negativo y precisión.[63]

Tabla de Confusión		Prueba de Oro	
		POSITIVO	NEGATIVO
Diagnóstico por Modelo de Inteligencia Artificial	POSITIVO	A (Verdaderos positivos)	B (Falsos positivos)
	NEGATIVO	C (Falsos negativos)	D (Verdaderos negativos)



La sensibilidad (S) se calculará con la fórmula: $S=A/ A+C$.

La especificidad (E) se calculará con la fórmula: $E= D/ D+B$.

El valor predictivo positivo (VPP) se calculará con la siguiente fórmula: $VPP= A/A+B$.

El valor predictivo negativo (VPN) se calculará con la siguiente fórmula: $VPN=D/D+C$.

La precisión (P) se calculará con la siguiente fórmula: $P= A+D/A+B+C+D$

Los resultados obtenidos serán expresados en porcentajes.

Las descripciones de los hallazgos radiológicos y diagnósticos serán expresadas en tablas de frecuencia y porcentajes.

Se evaluará la precisión de la inteligencia artificial para realizar el diagnóstico de COVID-19 mediante el uso de radiografía de tórax.

Finalmente se elaborará la discusión, conclusiones y recomendaciones.

3.6.2 Base de Datos

Para el procesamiento de datos y análisis estadístico correspondiente se utilizó el programa Microsoft® Excel 2019 y el software estadístico EPIDAT en su versión 4.2.

Se utilizó un ordenador con un procesador Intel Core i7 - 4790, con memoria RAM de 16 GB, GPU Nvidia 1650 de perfil bajo de 4GB de VRAM; con sistema operativo Windows 11.

Para el desarrollo de la prueba diagnóstica se utilizó el aplicativo “Lobe” de la empresa Microsoft® en su versión 0.8 para entrenar un modelo de inteligencia artificial por aprendizaje automático supervisado de clasificación de imágenes con 6677 radiografías de tórax, de las cuales 1314 son COVID 19 1414 NORMALES y 3499 radiografías patológicas no COVID 19.



Las etiquetas utilizadas fueron:

COVID: Para las radiografías de COVID-19

NO COVID: Para las radiografía normales y patológicas no COVID 19.

El conjunto de datos utilizados fue extraído de los siguientes repositorios:

<https://www.kaggle.com/pranavraikokte/covid19-image-dataset>

<https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>



CAPÍTULO IV: RESULTADOS DE LA INVESTIGACIÓN

Se obtuvo un registro total de 1155 placas radiográficas obtenidas de las bases de datos e historias clínicas según la facilidad, además de la organización del área de radiología y archivo de los tres hospitales citados en este trabajo, Cusco, mayo 2021 a abril 2022. Del total de placas radiográficas 770 fueron tomadas con fechas inferiores al año 2019 para asegurar que no correspondían a pacientes enfermos con SARS-COV-2; por otro lado, se consideraron placas tomadas durante el año 2020 y 2021 que corresponden a pacientes verificados con el diagnóstico de infección por SARS-COV-2.

Se obtuvo un total de 466 placas obtenidas de varones distribuidas en 204 de pacientes varones con la enfermedad y 262 sin la enfermedad, por otro lado, se obtuvieron 689 placas de mujeres distribuidas en 181 con la enfermedad y 508 sin la enfermedad.

Tabla 1. Distribución de placas tomadas de pacientes por sexo

		Varones	%	Mujeres	%	Total
Con	la	204	53%	181	47%	385
enfermedad						
Sin	la	262	34%	508	66%	770
enfermedad						
Total		466		689		1155

Las características demográficas de los pacientes de los cuales fueron tomadas las placas radiográficas muestran una distribución normal en cuanto a edades en los grupos con y sin la enfermedad.



Tabla 2. Distribución de edades de placas de pacientes sin la enfermedad

Edades	Número de placas sin la enfermedad
[18; 25]	30
(25; 32]	66
(32; 38]	87
(38; 45]	79
(45; 52]	105
(52; 59]	88
(59; 66]	102
(66; 72]	78
(72; 79]	69
(79; 86]	40
(86; 93]	25
(93; 100]	1



Tabla 3. Distribución de placas de pacientes con la enfermedad

Edades	Número de placas con la enfermedad
[18; 27]	35
(27; 36]	48
(36; 45]	48
(45; 54]	65
(54; 63]	55
(63; 72]	58
(72; 81]	46
(81; 90]	25
(90; 99]	5

Tabla 4. Tabla de confusión


		Gold Estándar		
		Enfermos	Sanos	Total
Diagnóstico por modelo de IA	Positivo	347	147	494
	Negativo	38	623	661
	Total	385	770	1155



Tabla 5. Resultados de desempeño del diagnóstico por IA para la COVID 19

Resultados	Valor
Sensibilidad	90.13%
Especificidad	80.91%
Valor predictivo positivo	70.24%
Valor predictivo negativo	94.25%
Precisión	83.98%
Razón de verosimilitud positiva	4.72
Razón de verosimilitud negativa	0.12

Figura 2. Curva ROC



El método diagnóstico por modelo de IA logró una exactitud de 83.98% (IC del 95%: 81.82% – 86.14%), una sensibilidad de 90.13% (IC del 95%: 87.02% – 93.24%), una especificidad de 80.91% (IC del 95%: 78.07% – 83.75%) con un área bajo la curva de 0.85.



CAPÍTULO V: DISCUSIÓN

5.1 Descripción de los hallazgos más relevantes y significativos

La investigación demostró una predominancia de sujetos femeninos sin la enfermedad siendo de un 66% del total de esta población, por otro lado, en el grupo de pacientes con la enfermedad se ve una predominancia de sujetos masculinos ocupando un 53% de la población total.

La distribución de edad en ambas poblaciones es normal, lo que respalda la toma aleatoria de placas.

De acuerdo con nuestra tabla de confusión (Tabla 4), se obtuvieron como verdaderos positivos a 347 pacientes, como falsos positivos 147, como falsos negativos 38 y verdaderos negativos 623. Calculándose de estos resultados una sensibilidad de 90.13%, una especificidad de 80.91%, el valor predictivo positivo 70.24%, valor predictivo negativo de 94.25%, una precisión de 83.98% y un área bajo la curva (AUC) de la característica operativa del receptor (ROC) de 0.85. El AUC obtenido indica que el método diagnóstico por IA funciona bien como prueba diagnóstica.

En la presente tesis el objetivo del estudio fue determinar la sensibilidad, especificidad, valor predictivo positivo, valor predictivo negativo y precisión de la prueba diagnóstica por inteligencia artificial; de igual manera, se planteó la hipótesis de que estos cinco productos fuesen altos; esta hipótesis fue validada por los resultados obtenidos.

5.2 Limitaciones del estudio

La ausencia de un sistema de placas radiográficas virtual o informático en uno de los hospitales escogidos para realizar el estudio presente.

El etiquetado erróneo de los nombres de los pacientes a quienes se les tomó las placas radiográficas utilizados, lo cual se presentó en algunas ocasiones.



5.3 Comparación crítica con la literatura existente

La investigación realizada requirió el entrenamiento de una Inteligencia Artificial (IA) la cuál aplicó un total de 6677 radiografías de tórax, de las cuales 1314 eran correspondientes a pacientes con la enfermedad, 1414 placas sin patología alguna y 3499 radiografías patológicas de enfermedades diferentes a la investigada. El conjunto de placas utilizadas para el entrenamiento de la IA aplicada es inferior al realizado por: Arias, Julian[7] que utilizó 79500 placas radiográficas, de las cuales era 8500 ejemplos de COVID 19; Murphy, K[10] que entrenó su IA con un total de 24678 placas radiográficas de las cuales 1540 pertenecieron a pacientes COVID 19; Wang L. [11] que utilizó 13870 placas de pacientes COVID; Wehbe, R utilizó 14788 imágenes COVID 19 positivas. El conjunto de placas utilizadas fue mayor que el utilizado por: Minaee, S[14] utilizó para el entrenamiento de su IA 2000 placas revisadas por un radiólogo previamente; Mohammadi R[18] que utilizó 112 placas COVID-19 para el entrenamiento de su IA y 33 placas para su validación, de igual modo aplicó 236 placas radiográficas normales para el entrenamiento y 55 para su validación.

La presente investigación utilizó para evaluar la IA de 1155 placas radiográficas divididas en dos poblaciones de 385 placas de pacientes con la enfermedad y de 770 pacientes sin la enfermedad; la cual es mayor que la población con la enfermedad usada por: Ali Al-Bawi[8] que contaba con 310 imágenes de casos confirmados de COVID-19; Murphy, K[10] que utilizó 223 placas de pacientes con prueba RT-PCR positiva para COVID 19 y 231 con resultado negativo para dicha prueba y menor que su población sin la enfermedad 864 imágenes de personas con neumonía y 654 placas de personas sanas. El número de placas utilizadas durante la prueba de la IA del presente estudio fue mayor que el utilizado por: Wang, L[11] que utilizó 358 placas radiográficas sin COVID 19 y 266 imágenes de pacientes COVID 19; **Taresh, M.[17] que utilizó 274 casos COVID 19, 380 casos de neumonía viral y 380 casos sanos;** Mohammadi R[18] que aplico 36 placas



COVID-19 y 73 placas normales. El número de placas utilizado es menor que: Minaee, S[14] utilizó 3000 placas en total para evaluar la funcionalidad de su IA; Wehbe, R[15] que utilizó un total de 2214 imágenes de pacientes COVID 19 positivos; **Lal Hussain[16] que utilizó placas COVID-19 130, neumonía bacteriana 145, neumonía viral no COVID-19 145 y normales 138;**

Se obtuvo una **sensibilidad** de prueba diagnóstica por modelo de IA de 90.13% que es inferior a la ofrecida por: Kiran Purohit[9] cuya sensibilidad de prueba diagnóstica fue 99.07%; Minghuan Wang[13] que obtuvo 92%; Minaee, S[14] que obtiene un 98%; Valencia, C[20] con un valor de 95.9% (esta prueba diagnóstica estaba aplicada a TCAR) y Wang, L[11] cuya sensibilidad es 91%. La sensibilidad de nuestra prueba diagnóstica es superior a la sensibilidad de: Javor, D[12] cuya sensibilidad es de 84.4% (este modelo de IA es aplicado a tomografías); Wehbe, R[15] cuyo valor fue de 71%; Huang, S[64] que utiliza métodos serológicos ELISA, IgM e IgG combinados con un resultado de 87.3% y GICA IgM e IgG combinados de 82.4%. La sensibilidad de la prueba diagnóstica es comparable con la obtenida por: Tareh, M.[17] con una sensibilidad de 90%; Lin Li[19] cuyo valor es de 90% (esta prueba diagnóstica se aplicó en placas tomográficas). La sensibilidad fue superior en comparación con las pruebas de antígenos según el estudio realizado por Langa L.[42] con un resultado de 95%.

La **especificidad** registrada del instrumento de prueba diagnóstica por modelo de IA es de 80.91% siendo esta inferior a la registrada por la prueba diagnóstica presentada por Kiran Purohit[9] cuya especificidad es de 98.88%; Javor, D[12] que es de 93.3%; Minghuan Wang[13] que obtuvo 85.1% (la prueba diagnóstica era aplicada a TC de tórax); Minaee, S[14] que obtuvo un 90%; Wehbe, R[15] con un valor de 92%; Huang, S[64] con un valor de 100%; Tareh, M.[17] con un valor de 95.8%; Lin Li[19] con un



valor de 96%; Valencia, C[20] con un valor de 98%, prueba de antígenos según Langa L.[42] con un resultado de 95 a 99%.

El **valor predictivo positivo VPP** registrado del instrumento de prueba diagnóstica por modelo de IA es de 70.24% que es inferior a la presentada por: Wang, L[11] en cuyo estudio es de 98.9%, Minghuan Wang[13] que es 79%.

El **valor predictivo negativo VPN** registrado del instrumento de prueba diagnóstica por modelo de IA es de 94.25% que es superior al presentado por: Wang, L[11] en cuyo estudio es de 91.3%; siendo comparable a los resultados obtenidos por Minghuan Wang[13] con VPN de 94.8%.

La prueba diagnóstica por modelo de IA tiene una **precisión** de 83.98% la cual es inferior a la presentada por Arias, Julian[7] que obtuvo un 91.5%; Ali Al-Bawi[8] cuya precisión de prueba diagnóstica fue de 98.52%; Kiran Purohit[9] que obtuvo 98,97%; Wang, L[11] con una precisión de 93.3%; **Taresh, M.[17] con una precisión de 95.7%**; Mohammadi R[18] cuya precisión es mayor al 90%; Valencia, C[20] cuyo resultado es de 96%. La precisión fue comparable con la obtenida por Wehbe, R[15] cuyo resultado fue 83%.

El **área bajo la curva ROC** resultante de la investigación del instrumento de prueba diagnóstica por IA es de 0.85, siendo mayor que: los resultados obtenidos por Murphy, K[10] de 0.81 y el presentado por Kahn, M[42] con un valor de 0.66. Siendo menor que: Javor, D[12] que obtuvo un valor de 0.956; Minghuan Wang[13] que obtuvo 0.953; Wehbe, R[15] con un valor de 0.90; Lal Hussain[16] que presenta un valor de 0.87; **Taresh, M.[17] cuyo valor es de 0.97**; Mohammadi R[18] con un valor de 0.99; Lin Li[19] con un resultado de 0.96 y Valencia, C[20] con un AUC de 0.975; Huang, S[64] para IgG es de 0.934, IgM es de 0.812 y para ambos es de 0.983.



5.4 Implicancias del estudio

La inteligencia artificial para el diagnóstico de COVID 19 dado que presenta una alta sensibilidad, especificidad, VPP, VPN la convierte en un buen método diagnóstico para la COVID 19. Su uso no requiere un conocimiento avanzado de informática y la interpretación de resultados es sencilla, lo que facilita su extensión para una aplicabilidad potencial en las redes de salud.



CONCLUSIONES

Primera. La precisión de prueba diagnóstica por modelo de IA es de 83.98% y el AUC es de 0.85, lo que implica que es un buen método diagnóstico no invasivo.

Segunda. La prueba diagnóstica por modelo de IA se caracteriza por tener un alto valor predictivo negativo, lo que la hace útil al discriminar verdaderos negativos (pacientes sin la enfermedad)

Tercera. Las redes neuronales artificiales requieren un nivel complejo de conocimiento para su formulación y calibración dependiendo su propósito, sin embargo, hoy en día se cuentan con herramientas de libre acceso; que si bien implican: un equipo de hardware adecuado, la recolección de datos y el tiempo de entrenamiento para el fin buscado; que facilita la confección de la IA y su uso para personas no expertas del tema.

Cuarta. La prueba diagnóstica propuesta tiene menor potencia que otras mencionadas, sin embargo, es adecuada como método de diagnóstico.

RECOMENDACIONES

Consideramos imprescindible que las escuelas de medicina del Perú implementen cursos que fomenten y enseñen la relación, además de las aplicaciones entre la inteligencia artificial y la medicina; en este sentido, aseguraremos que futuros profesionales de la salud tengan en cuenta nuevas tecnologías diagnósticas de enfermedades, que abarcan mucho más que su aplicación meramente a imágenes (radiología y patología), sino del mismo modo a diferentes tipos de información de relevancia clínica.

En el área de ciencias de la salud se requiere de grandes grupos de datos para concretar investigaciones y lograr herramientas de mayor precisión. El uso de conjunto de datos (datasets) de libre acceso es de gran ayuda al formular nuevos modelos de aprendizaje



automático. Por lo que sugerimos a los profesionales de la salud e investigadores a fines el uso y aporte de datasets para la investigación en medicina.



BIBLIOGRAFÍA

- [1] Murrugarra-Suarez S, Lora-Loza M, Cabrejo-Paredes J, Mucha-Hospinal L, Fernandez-Cosavalente H, Murrugarra-Suarez S, et al. Factores asociados a mortalidad en pacientes Covid- 19 en un Hospital del norte de Perú. *Revista Del Cuerpo Médico Hospital Nacional Almanzor Aguinaga Asenjo* 2020;13:378–85. <https://doi.org/10.35434/RCMHNAAA.2020.134.773>.
- [2] Pighi P. Coronavirus en Perú: 5 factores que explican por qué es el país con la mayor tasa de mortalidad entre los más afectados por la pandemia. *BBC News Mundo* 2020. <https://www.bbc.com/mundo/noticias-america-latina-53940042> (accessed May 17, 2022).
- [3] Ministerio de Salud. Resolución Ministerial N° 905 – 2020-MINSA. Lima: 2020.
- [4] Ministerio de Salud Perú. Documento técnico: prevención, diagnóstico y tratamiento de personas afectadas por COVID-19 en el Perú 2020.
- [5] Ministerio de Salud Perú. Documento Técnico Atención y Manejo Clínico de Casos de COVID-19 Escenario de Transmisión Focalizada. Lima: 2020.
- [6] Wang S, Zha Y, Li W, Wu Q, Li X, Niu M, et al. A fully automatic deep learning system for COVID-19 diagnostic and prognostic analysis. *European Respiratory Journal* 2020;56:2000775. <https://doi.org/10.1183/13993003.00775-2020>.
- [7] Arias-Londono JD, Gomez-Garcia JA, Moro-Velazquez L, Godino-Llorente JI. Artificial Intelligence Applied to Chest X-Ray Images for the Automatic Detection of COVID-19. A Thoughtful Evaluation Approach. *IEEE Access* 2020;8:226811–27. <https://doi.org/10.1109/ACCESS.2020.3044858>.
- [8] Al-Bawi A, Al-Kaabi K, Jeryo M, Al-Fatlawi A. CCBLOCK: an effective use of deep learning for automatic diagnosis of COVID-19 using X-ray images. *Research on Biomedical Engineering* 2020. <https://doi.org/10.1007/s42600-020-00110-7>.
- [9] Purohit K, Kesarwani A, Kisku DR, Dalui M. COVID-19 detection on chest X-Ray and CT Scan images using multi-image augmented deep learning model. *BioRxiv* 2020. <https://doi.org/10.1101/2020.07.15.205567>.
- [10] Murphy K, Smits H, Knoop AJG, Korst MBJM, Samson T, Scholten ET, et al. COVID-19 on Chest Radiographs: A Multireader Evaluation of an Artificial Intelligence System. *Radiology* 2020;296:E166–72. <https://doi.org/10.1148/radiol.2020201874>.
- [11] Wang L, Lin ZQ, Wong A. COVID-Net: a tailored deep convolutional neural network design for detection of COVID-19 cases from chest X-ray images. *Scientific Reports* 2020;10:19549. <https://doi.org/10.1038/s41598-020-76550-z>.
- [12] Javor D, Kaplan H, Kaplan A, Puchner SB, Krestan C, Baltzer P. Deep learning analysis provides accurate COVID-19 diagnosis on chest computed tomography. *European Journal of Radiology* 2020;133:109402. <https://doi.org/10.1016/j.ejrad.2020.109402>.
- [13] Wang M, Xia C, Huang L, Xu S, Qin C, Liu J, et al. Deep learning-based triage and analysis of lesion burden for COVID-19: a retrospective study with external validation. *The Lancet Digital Health* 2020;2:e506–15. [https://doi.org/10.1016/S2589-7500\(20\)30199-0](https://doi.org/10.1016/S2589-7500(20)30199-0).



- [14] Minaee S, Kafieh R, Sonka M, Yazdani S, Jamalipour Soufi G. Deep-COVID: Predicting COVID-19 from chest X-ray images using deep transfer learning. *Med Image Anal* 2020;65:101794. <https://doi.org/10.1016/j.media.2020.101794>.
- [15] Wehbe RM, Sheng J, Dutta S, Chai S, Dravid A, Barutcu S, et al. DeepCOVID-XR: An Artificial Intelligence Algorithm to Detect COVID-19 on Chest Radiographs Trained and Tested on a Large US Clinical Dataset. *Radiology* 2020:203511. <https://doi.org/10.1148/radiol.2020203511>.
- [16] Hussain L, Nguyen T, Li H, Abbasi AA, Lone KJ, Zhao Z, et al. Machine-learning classification of texture features of portable chest X-ray accurately classifies COVID-19 lung infection. *BioMedical Engineering Online* 2020;19:1–18. <https://doi.org/10.1186/s12938-020-00831-x>.
- [17] Taresh M, Zhu N, Ali Ali TA. Transfer learning to detect COVID-19 automatically from X-ray images, using convolutional neural networks. *MedRxiv* 2020:1–14. <https://doi.org/10.1101/2020.08.25.20182170>.
- [18] Mohammadi R, Salehi M, Ghaffari H, Rohani AA, Reiazi R. Transfer Learning-Based Automatic Detection of Coronavirus Disease 2019 (COVID-19) from Chest X-ray Images. *J Biomed Phys Eng* 2020;10:559–68. <https://doi.org/10.31661/jbpe.v0i0.2008-1153>.
- [19] Li L, Qin L, Xu Z, Yin Y, Wang X, Kong B, et al. Using Artificial Intelligence to Detect COVID-19 and Community-acquired Pneumonia Based on Pulmonary CT: Evaluation of the Diagnostic Accuracy. *Radiology* 2020;296:E65–71. <https://doi.org/10.1148/radiol.2020200905>.
- [20] Valencia C, Serrano X. Determinación de COVID-19 por TCAR: Estimación Diagnóstica Médica VS Sistema de Inteligencia Artificial. Universidad Nacional Autónoma de México, 2021.
- [21] Hao Y, Xu T, Hu H, Wang P, Bai Y. Prediction and analysis of Corona virus disease 2019. *PLoS ONE* 2020;15:e0239960. <https://doi.org/10.1371/journal.pone.0239960>.
- [22] OPS/OMS. Actualización Epidemiológica: Nuevo coronavirus (2019-nCoV). Washington, D.C: 2020.
- [23] OPS/OMS. Actualización Epidemiológica: Nuevo coronavirus (COVID-19). Washington, D.C.: OPS/OMS: 2020.
- [24] Jin Y, Yang H, Ji W, Wu W, Chen S, Zhang W, et al. Virology, Epidemiology, Pathogenesis, and Control of COVID-19. *Viruses* 2020;12:372. <https://doi.org/10.3390/v12040372>.
- [25] Gorbalenya AE, Baker SC, Baric RS, de Groot RJ, Drosten C, Gulyaeva AA, et al. The species Severe acute respiratory syndrome-related coronavirus: classifying 2019-nCoV and naming it SARS-CoV-2. *Nature Microbiology* 2020;5:536–44. <https://doi.org/10.1038/s41564-020-0695-z>.
- [26] Gobierno regional Cusco/ GERESA Cusco. Sala situacional COVID 19 región Cusco. Cusco: 2021.
- [27] Johns Hopkins University. COVID-19 Data Repository by the Center for Systems Science and Engineering (CSSE) at Johns Hopkins University 2021:19.



- <https://www.iadb.org/es/coronavirus/situacion-actual-de-la-pandemia> (accessed March 20, 2021).
- [28] Liu J, Liao X, Qian S, Yuan J, Wang F, Liu Y, et al. Community Transmission of Severe Acute Respiratory Syndrome Coronavirus 2, Shenzhen, China, 2020. *Emerging Infectious Diseases* 2020;26:1320–3. <https://doi.org/10.3201/eid2606.200239>.
- [29] Struyf T, Deeks JJ, Dinnes J, Takwoingi Y, Davenport C, Leeflang MM, et al. Signs and symptoms to determine if a patient presenting in primary care or hospital outpatient settings has COVID-19. *Cochrane Database of Systematic Reviews* 2021. <https://doi.org/10.1002/14651858.CD013665.pub2>.
- [30] Ou M, Zhu J, Ji P, Li H, Zhong Z, Li B, et al. Risk Factors of Severe Cases with COVID-19: A Meta-Analysis. *Epidemiology and Infection* 2020;148. <https://doi.org/10.1017/S095026882000179X>.
- [31] Grant MC, Geoghegan L, Arbyn M, Mohammed Z, McGuinness L, Clarke EL, et al. The prevalence of symptoms in 24,410 adults infected by the novel coronavirus (SARS-CoV-2; COVID-19): A systematic review and meta-analysis of 148 studies from 9 countries. *PLOS ONE* 2020;15:e0234765. <https://doi.org/10.1371/journal.pone.0234765>.
- [32] Martínez Chamorro E, Díez Tascón A, Ibáñez Sanz L, Ossaba Vélez S, Borrueal Nacenta S. Radiologic diagnosis of patients with COVID-19. *Radiologia (Panama)* 2021;63:56–73. <https://doi.org/10.1016/j.rx.2020.11.001>.
- [33] Torres-Criollo LM, Ramírez-Coronel AA, Martínez-Suárez PC, Romero-Sacoto LA, Mesa-Cano IC, González-León FM, et al. Variables clínicas y paraclínicas predictoras de pronóstico en pacientes con COVID-19: Revisión Sistemática. *AVFT – Archivos Venezolanos de Farmacología y Terapéutica* 2021;39. <https://doi.org/10.5281/zenodo.4256990>.
- [34] Khalili M, Karamouzian M, Nasiri N, Javadi S, Mirzazadeh A, Sharifi H. Epidemiological Characteristics of COVID-19: A Systematic Review and Meta-Analysis. *Epidemiology and Infection* 2020;148. <https://doi.org/10.1017/S0950268820001430>.
- [35] Nasiri MJ, Haddadi S, Tahvildari A, Farsi Y, Arbabi M, Hasanzadeh S, et al. COVID-19 Clinical Characteristics, and Sex-Specific Risk of Mortality: Systematic Review and Meta-Analysis. *Frontiers in Medicine* 2020;7:459. <https://doi.org/10.3389/fmed.2020.00459>.
- [36] Vakili K, Fathi M, Pezeshgi A, Mohamadkhani A, Hajiesmaeili M, Rezaei-Tavirani M, et al. Critical complications of COVID-19: A descriptive meta-analysis study. *Reviews in Cardiovascular Medicine* 2020;21:433–42. <https://doi.org/10.31083/j.rcm.2020.03.129>.
- [37] Galbadage T, Peterson BM, Awada J, Buck AS, Ramirez DA, Wilson J, et al. Systematic Review and Meta-Analysis of Sex-Specific COVID-19 Clinical Outcomes. *Frontiers in Medicine* 2020;7:348. <https://doi.org/10.3389/fmed.2020.00348>.
- [38] Alarcón-Rodríguez J, Fernández-Velilla M, Ureña-Vacas A, Martín-Pinacho JJ, Rigual-Bobillo JA, Jaureguizar-Oriol A, et al. Radiological management and follow-up of post-COVID-19 patients. *Radiologia (Panama)* 2021. <https://doi.org/10.1016/j.rx.2021.02.003>.



- [39] Centro Nacional de Epidemiología P y C de E. Estudio Incidencia, prevalencia y factores de riesgo para la infección por virus SARS-CoV-2, estudio poblacional en el Ministerio de Salud. Lima: 2021.
- [40] Goudouris ES. Laboratory diagnosis of COVID-19. *Jornal de Pediatria* 2021;97:7–12. <https://doi.org/10.1016/j.jpmed.2020.08.001>.
- [41] Dinnes J, Deeks JJ, Berhane S, Taylor M, Adriano A, Davenport C, et al. Rapid, point-of-care antigen and molecular-based tests for diagnosis of SARS-CoV-2 infection. *Cochrane Database of Systematic Reviews* 2021;2021. <https://doi.org/10.1002/14651858.CD013705.pub2>.
- [42] Kahn M, Schuierer L, Bartenschlager C, Zellmer S, Frey R, Freitag M, et al. Performance of antigen testing for diagnosis of COVID-19: a direct comparison of a lateral flow device to nucleic acid amplification based tests. *BMC Infectious Diseases* 2021;21:1–7. <https://doi.org/10.1186/S12879-021-06524-7/TABLES/4>.
- [43] Russell S, Norvig P, Ernest D. *Artificial intelligence : a modern approach*. 4th ed. New Jersey: 2020.
- [44] Poole DL, Mackworth AK. *Computational intelligence*. Cambridge: Cambridge University Press; 2010.
- [45] Domingos P. *The Master Algorithm: How the Quest for the Ultimate Learning Machine Will Remake Our World*. 1st ed. New York: Basic Books; 2015.
- [46] Mitchell T. *Machine Learning*. McGraw-Hill Science/Engineering/Math; 1997.
- [47] Alpayadin E. *Introduction to Machine Learning*. MIT Press; 2020.
- [48] Lecun Y, Bengio Y, Hinton G. Deep learning. *Nature* 2015;521:436–44. <https://doi.org/10.1038/nature14539>.
- [49] Mohri M, Rostamizadeh A, Talwalkar A. *Foundations of Machine Learning*. MIT Press; 2012.
- [50] Goodfellow I, Bengio Y, Courville A. *Deep Learning*. MIT Press; 2016.
- [51] Pouly M, Koller T, Gottfrois P, Lionetti S. Artificial intelligence in image analysis—fundamentals and new developments. *Hautarzt* 2020;71:660–8. <https://doi.org/10.1007/s00105-020-04663-7>.
- [52] Bengio Y. Learning Deep Architectures for AI. *Foundations and Trends® in Machine Learning* 2009;2:1–127. <https://doi.org/10.1561/22000000006>.
- [53] Valueva MV, Nagornov NN, Lyakhov PA, Valuev GV, Chervyakov NI. Application of the residue number system to reduce hardware costs of the convolutional neural network implementation. *Mathematics and Computers in Simulation* 2020;177:232–43. <https://doi.org/10.1016/j.matcom.2020.04.031>.
- [54] Esteva A, Robicquet A, Ramsundar B, Kuleshov V, DePristo M, Chou K, et al. A guide to deep learning in healthcare. *Nature Medicine* 2019;25:24–9. <https://doi.org/10.1038/s41591-018-0316-z>.
- [55] Miotto R, Wang F, Wang S, Jiang X, Dudley JT. Deep learning for healthcare: Review, opportunities and challenges. *Briefings in Bioinformatics* 2017;19:1236–46. <https://doi.org/10.1093/bib/bbx044>.



- [56] Shen J, Zhang CJP, Jiang B, Chen J, Song J, Liu Z, et al. Artificial Intelligence Versus Clinicians in Disease Diagnosis: Systematic Review. *JMIR Medical Informatics* 2019;7:e10010. <https://doi.org/10.2196/10010>.
- [57] Desai SB, Pareek A, Lungren MP. Deep learning and its role in COVID-19 medical imaging. *Intelligence-Based Medicine* 2020;3-4:100013. <https://doi.org/10.1016/j.ibmed.2020.100013>.
- [58] McBee MP, Awan OA, Colucci AT, Ghobadi CW, Kadom N, Kansagra AP, et al. Deep Learning in Radiology. *Academic Radiology* 2018;25:1472-80. <https://doi.org/10.1016/j.acra.2018.02.018>.
- [59] Ng M-Y, Lee EYP, Yang J, Yang F, Li X, Wang H, et al. Imaging Profile of the COVID-19 Infection: Radiologic Findings and Literature Review. *Radiology: Cardiothoracic Imaging* 2020;2:e200034. <https://doi.org/10.1148/ryct.2020200034>.
- [60] Ai T, Yang Z, Hou H, Zhan C, Chen C, Lv W, et al. Correlation of Chest CT and RT-PCR Testing for Coronavirus Disease 2019 (COVID-19) in China: A Report of 1014 Cases. *Radiology* 2020;296:E32-40. <https://doi.org/10.1148/radiol.2020200642>.
- [61] Rubin GD, Ryerson CJ, Haramati LB, Sverzellati N, Kanne JP, Raouf S, et al. The Role of Chest Imaging in Patient Management During the COVID-19 Pandemic: A Multinational Consensus Statement From the Fleischner Society. *Chest* 2020;158:106-16. <https://doi.org/10.1016/j.chest.2020.04.003>.
- [62] Obuchowski NA. Sample size calculations in studies of test accuracy. *Statistical Methods in Medical Research* 1998;7:371-92. <https://doi.org/10.1177/096228029800700405>.
- [63] Ministerio de Salud, Instituto Nacional de salud. LINEAMIENTOS DE VALIDACIÓN DE PROCEDIMIENTOS DIAGNÓSTICOS DEL SARS CoV-2. Documento Técnico 2020.
- [64] Huang S, Lin C, Yan M, Li H, Liu T, Michael W, et al. Rapid Detection of COVID-19 by Serological Methods and the Evaluation of Diagnostic Efficacy of IgM and IgG. *Clinical Laboratory* 2020;66:2327-33. <https://doi.org/10.7754/Clin.Lab.2020.200617>.



ANEXOS



Anexo 1. Desarrollo del modelo de Inteligencia Artificial

Para el desarrollo de la prueba diagnóstica se utilizó el aplicativo “Lobe” de la empresa Microsoft® en su versión 0.8 para entrenar un modelo de inteligencia artificial por aprendizaje automático supervisado de clasificación de imágenes con 6677 radiografías de tórax, de las cuales 1314 son COVID 19 1414 NORMALES y 3499 radiografías patológicas no COVID 19.

Las etiquetas utilizadas fueron:

- COVID: Para las radiografías de COVID-19
- NO COVID: Para las radiografía normales y patológicas no COVID 19.

El conjunto de datos utilizados fue extraído de los siguientes repositorios:

- <https://www.kaggle.com/pranavraikokte/covid19-image-dataset>
- <https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>

A la conclusión de este trabajo de investigación el modelo de Inteligencia Artificial será publicada en la plataforma GitHub



Anexo 2. Matriz de Consistencia

Título	Variable	Problema	Objetivo	Hipótesis
Uso del aprendizaje automático para el diagnóstico de Covid 19	Sensibilidad	¿Cuál es la sensibilidad de la inteligencia artificial para el diagnóstico de COVID 19?	Determinar la sensibilidad de la inteligencia artificial para el diagnóstico de COVID 19.	La sensibilidad de la inteligencia artificial para el diagnóstico de COVID 19 es superior al 90%.
Variables específicas	Especificidad	¿Cuál es especificidad de la inteligencia artificial para el diagnóstico de COVID 19?	Determinar la especificidad de la inteligencia artificial para el diagnóstico de COVID 19	La especificidad de la inteligencia artificial para el diagnóstico de COVID 19 es superior al 90%.
	Valor predictivo negativo	¿Cuál es el valor predictivo negativo de la inteligencia artificial para el diagnóstico de COVID 19?	Determinar el valor predictivo negativo de la inteligencia artificial para el diagnóstico de COVID 19	El valor predictivo negativo de la inteligencia artificial para el diagnóstico de COVID 19 es mayor 90%.
	Valor predictivo positivo	¿Cuál es el valor predictivo positivo de la inteligencia artificial para el diagnóstico de COVID 19?	Determinar el valor predictivo positivo de la inteligencia artificial para el diagnóstico de COVID 19	El valor predictivo positivo de la inteligencia artificial para el diagnóstico de COVID 19 es alta.
	Precisión	¿Cuál es la precisión de la inteligencia artificial para el diagnóstico de COVID 19?	Determinar la precisión de la inteligencia artificial para el diagnóstico de COVID 19	La precisión de la inteligencia artificial para el diagnóstico de COVID 19 es mayor a 90%.



Anexo 3. Estudio Piloto

Objetivo: Calcular la sensibilidad de la prueba diagnóstica “clasificación de imágenes de radiografía de tórax por aprendizaje automático” para el diagnóstico de COVID-19

Selección de sujetos: Pacientes con COVID-19 diagnosticados con RT-PCR que tengan una radiografía de tórax durante la enfermedad.

Método: Se analizaron 63 radiografías de tórax de pacientes con COVID-19 confirmadas por la prueba RT-PCR, la radiografía se tomó durante la sintomatología del COVID-19. Se calculará la sensibilidad con la relación de los que salen “positivo” a la prueba diagnóstica a estudiar con la totalidad de pacientes estudiados.

Resultados: De los 63 pacientes diagnosticados con COVID-19 por RT-PCR, salieron “positivos” para la prueba “clasificación de imágenes de radiografía de tórax por aprendizaje automático” fueron 62. La sensibilidad resultante es de 98.4%

Conclusiones: La prueba diagnóstica “clasificación de imágenes de radiografía de tórax por aprendizaje automático” tuvo una alta sensibilidad en el estudio piloto, por lo tanto, se justifica continuar con el estudio.



Anexo 4. Ficha de Recolección de Datos

Ficha de Recolección de Datos “Con la Enfermedad”	
Número de Historia Clínica
Apellidos y Nombres
Prueba COVID-19 Positiva	RT-PCR () ANTIGÉNICA ()
Fecha de la Prueba/...../20...
Fecha de Radiografía de Tórax/...../20...

Ficha de Recolección de Datos “Sin la Enfermedad”	
Número de Historia Clínica
Apellidos y Nombres
Fecha de Radiografía de Tórax/...../20...

Los datos serán ingresados mediante la plataforma Google Forms.

Enlace de Ficha de Recolección de Datos “Con la Enfermedad”:

https://docs.google.com/forms/d/e/1FAIpQLScUVtyS35Lk4uRCfyxKVcks5dNVvrO4DksHeSPGUzbW5D5VVSQ/viewform?usp=sf_link

Enlace de Ficha de Recolección de Datos “Sin la Enfermedad”

https://docs.google.com/forms/d/e/1FAIpQLSdLskCDIzKDgGsilX3rP6DxdwEEqgd5sMDmllYH--VAq30yQ/viewform?usp=pp_url



PRESUPUESTO

Tipo	Categoría	Recurso	Descripción	Monto
Recursos disponibles	Infraestructura	Equipo	Ordenador	S/ 6,000.00
		Equipo	Tablet	S/ 3,000.00
		Equipo	Memoria USB	S/ 30.00
		Vehículo	Transporte a los hospitales para la recolección de datos	S/ 300.00
Recursos necesarios	Materiales	Medio millar de hojas bond	Para impresiones	S/ 15.00
		Impresiones	Impresión del proyecto	S/ 50.00
		CD	Entrega del proyecto	S/ 20.00
		Portafolio	Presentación del proyecto	S/ 50.00
		Materiales de escritorio	Llenado y firma de documentos	S/ 20.00
Total				S/ 9,485.00

El proyecto de investigación será autofinanciado por los autores.



CRONOGRAMA

Actividades	2021					2022			
	Enero	Febrero	Marzo	Abril	Mayo a Diciembre	Enero	Febrero	Marzo	Abril
Elección del Tema									
Revisión de la literatura									
Desarrollo del modelo de inteligencia artificial									
Elaboración del Capítulo I, II									
Revisión y corrección del Capítulo I, II									
Ejecución de la Prueba Piloto									
Elaboración del Capítulo III									
Elaboración y corrección del Capítulo III									
Inicio de la investigación y recolección de datos									
Elaboración del Capítulo IV y V									
Entrega de la Tesis Final									



"Año del Bicentenario del Perú: 200 Años de Independencia"
"Decenio de la Igualdad de Oportunidades para Mujeres y Hombres"

RESOLUCION DE GERENCIA RED ASISTENCIAL CUSCO N° 309 -GRACU-ESSALUD-2021

CUSCO, 09 JUL. 2021

VISTO,

La Nota de la Oficina de Capacitación, Investigación y Docencia N° 124-OCID-GRACU-ESSALUD-2021 de fecha 23 de junio del 2021, con el cual, solicita la emisión de la resolución de autorización de ejecución de Proyecto de Investigación;

CONSIDERANDO:

Que, mediante Resolución del Instituto de Evaluación de Tecnologías en Salud e Investigación N° 46-IETSI-ESSALUD-2019 de fecha 03 de junio del 2019, se resuelve aprobar la Directiva N° 003-IETSI-ESSALUD-2019 V.01. "Directiva que Regula el Desarrollo de la Investigación en Salud"; cuyo objetivo es establecer los lineamientos para la aprobación, ejecución, supervisión, difusión, priorización y promoción de las actividades y estudios de investigación en salud a ser desarrollados en EsSalud;

Que, en el numeral 1 del Capítulo III – Disposiciones Generales de la Directiva N° 003-IETSI-ESSALUD-2019 V.01, se establece que, la distinción entre ensayos clínicos y estudios observacionales se realiza según la definición regulatoria de ensayo clínico contenida en el Reglamento de Ensayos Clínicos y en esta Directiva, la misma que necesariamente corresponde a la definición metodológica. Los estudios que no cumplan la definición regulatoria de ensayo clínico serán considerados como estudios observacionales;

Que, en el numeral 2.1.1. de la Directiva N° 003-IETSI-ESSALUD-2019 V.01, se establece que, los estudios observacionales se desarrollan mediante las siguientes modalidades: INSTITUCIONAL, EXTRA INSTITUCIONAL, COLABORATIVA Y TESIS DE PREGRADO;

Que, en el numeral 2.2.1 de la Directiva N° 003-IETSI-ESSALUD-2019 V.01, se establece el proceso de aprobación de los estudios observacionales y la presentación de los documentos por parte del investigador principal (IP) o el coinvestigador responsable ante la Instancia Encargada del Área de Investigación (IEAI);

Que, en el numeral 2.2.2 de la Directiva N° 003-IETSI-ESSALUD-2019 V.01, se establece que, la IEAI recibe el expediente y verifica el cumplimiento de los requisitos. Luego, envía el expediente al Comité Institucional de Ética en Investigación (CIEI) en un plazo que no exceda de tres días útiles;

Que, en el numeral 2.2.5 de la Directiva N° 003-IETSI-ESSALUD-2019 V.01, se establece que, una vez aprobado el protocolo por el CIEI, la Gerencia evalúa el expediente y emite una carta dirigida al investigador con su decisión de autorizar o no el inicio del estudio en un plazo no mayor a catorce días calendario. La IEAI comunica la decisión al Comité y al IP haciéndole llegar la carta o certificado de aprobación del comité y de la gerencia. El Gerente del Órgano puede delegar esta función de autorización de estudios observacionales a otra instancia que considere conveniente, por ejemplo, a la IEAI o al director del establecimiento;

Que, mediante Resolución de Gerencia de Red Asistencial Cusco N° 305-GRACU-ESSALUD-2020 de fecha 21 de setiembre del 2020 y su modificatoria con Resolución N° 329-GRACU-ESSALUD-2020 de fecha 08 de octubre del 2020, se resuelve, conformar, a partir de la fecha y por el periodo de tres (03) años, el Comité Institucional de Ética en Investigación (CIEI) de la Gerencia de Red Asistencial Cusco del Seguro Social de Salud "ESSALUD";



..//

www.essalud.gob.pe

Av. Anselmo Álvarez s/n
Wanchaq
Cusco, Perú
Tel.: 084-582890 y 084-228428



"Año del Bicentenario del Perú: 200 Años de Independencia"
"Decenio de la Igualdad de Oportunidades para Mujeres y Hombres"

RESOLUCION DE GERENCIA RED ASISTENCIAL CUSCO N° 309 -GRACU-ESSALUD-2021 //..2

Que, mediante documento del visto, la Oficina de Capacitación, Investigación y Docencia, en uso de sus atribuciones ha verificado el cumplimiento de los requisitos del Proyecto de Investigación con el Título: "USO DE INTELIGENCIA ARTIFICIAL PARA EL DIAGNOSTICO DE COVID-19 A TRAVES DE RADIOGRAFIA DE TORAX EN EL HOSPITAL NACIONAL ADOLFO GUEVARA VELASCO, HOSPITAL REGIONAL Y HOSPITAL ANTONIO LORENA, CUSCO-PERU, PERIODO 2020-2021", presentado por los estudiantes: PAVEL EDMUNDO LUNA MANCILLA Y SHARON ANGELICA VARGAS QUISCA, para optar el título profesional de Médico Cirujano en la Universidad Andina del Cusco. Dicho proyecto de investigación, entre otros, cuenta con la aprobación del Comité de Ética en Investigación con Nota N° 32-CE-GRACU-ESSALUD-2021 de fecha 23 de junio del 2021; asimismo, cuenta con la opinión favorable de la sede donde se realizará la investigación según Anexo 6 suscrito por el Doctor Erick Gustavo Flores Revilla, Jefe del Servicio de Diagnóstico por Imágenes del Hospital Nacional "Adolfo Guevara Velasco";

Que, estando a los considerandos expuestos y en uso de las facultades conferidas mediante Directiva N° 003-IETSI-ESSALUD-2019 V.01 y Resolución de Presidencia Ejecutiva N° 471-PE-ESSALUD-2021:

SE RESUELVE:

PRIMERO.- AUTORIZAR, la ejecución del Proyecto de Investigación con el Título: "USO DE INTELIGENCIA ARTIFICIAL PARA EL DIAGNOSTICO DE COVID-19 A TRAVES DE RADIOGRAFIA DE TORAX EN EL HOSPITAL NACIONAL ADOLFO GUEVARA VELASCO, HOSPITAL REGIONAL Y HOSPITAL ANTONIO LORENA, CUSCO-PERU, PERIODO 2020-2021", presentado por los estudiantes: PAVEL EDMUNDO LUNA MANCILLA Y SHARON ANGELICA VARGAS QUISCA, a realizarse en el Servicio de Diagnóstico por Imágenes del Hospital Nacional "Adolfo Guevara Velasco" de ESSALUD Cusco.

SEGUNDO.- DISPONER que los investigadores: PAVEL EDMUNDO LUNA MANCILLA Y SHARON ANGELICA VARGAS QUISCA, prosigan con todas las acciones vinculadas con el tema de investigación, las cuales deberán ajustarse al cumplimiento de las normas y directivas de la institución establecidas para tal fin.

TERCERO.- DISPONER que las instancias respectivas brinden las facilidades del caso para la ejecución del Proyecto de Investigación autorizado con la presente Resolución.

REGÍSTRESE Y COMUNÍQUESE.

DR. CARLOS B. MEZA VILCA
CIMP. 66319 RNA. A08049
RED ASISTENCIAL CUSCO
GERENTE



CBMV/acq.
Cc. OCID, CE, DHNAGV, INTERESADOS, ARCH.

1307	2021	2684
------	------	------

www.essalud.gob.pe

Av. Anselmo Álvarez s/n
Wanchaq
Cusco, Perú
Tel.: 084-582890 y 084-228428



HOSPITAL REGIONAL CUSCO
DIAGNOSTICO POR IMAGENES



"Año del Fortalecimiento de la Soberanía Nacional"

Cusco, 18 de marzo del 2022

INFORME N° 051-2022-HRC-DE DAD-JSDI-ADM1

A : Dr. José Pinares Valencia
Director Ejecutivo del Hospital Regional Cusco

DE : Dra. Roció J. Herrera Aedo
Administrador del servicio de Diagnóstico por Imágenes

ASUNTO : Aceptación de Tesistas de la escuela profesional de Medicina Humana de la UAC

REFERENCIA : Carta N° 01-2022-CIC-EPMH-FSCA-UAC

Tengo a bien dirigirme a Usted, para saludarlo cordialmente y mediante el presente informarle respecto al documento de la referencia, en el cual la escuela profesional de Medicina Humana de la Universidad Andina de Cusco, presenta a los tesistas Sharon Angélica Vargas Quisca y a Pavel Edmundo Luna Mancilla, para recolectar información del Registro de Rayos X, para su proyecto de Tesis titulado "Uso de Inteligencia Artificial para el diagnóstico de COVID 19 a través de radiografía de tórax en el Hospital Adolfo Guevara Velasco, Hospital Regional y Hospital Antonio Lorena, Cusco Perú, periodo 2020-2021", por lo que, el Servicio de Diagnóstico por Imágenes **ACEPTA LA SOLICITUD** para realizar la recolección de datos en el Servicio de Diagnóstico por Imágenes.

Sin otro particular aprovecho la ocasión para reiterarle las consideraciones de estima personal

Atentamente,

Gobierno Regional Cusco
Gerencia Regional de Salud Cusco
Hospital Regional Cusco
M.C. Rocio J. Herrera Aedo
Administrador del Servicio de
Diagnóstico por Imágenes

004295

DIRECCION REGIONAL DE SALUD CUSCO
HOSPITAL REGIONAL DEL CUSCO
TRAMITE DOCUMENTARIO
18 MAR. 2022
Hora J. 42 cc
Firma



GOBIERNO REGIONAL CUSCO

DIRECCION REGIONAL DE SALUD
HOSPITAL ANTONIO LORENA
OFICINA DE INVESTIGACION, DOCENCIA Y CAPACITACION

"Año del Fortalecimiento de la Soberanía Nacional"



Cusco, 25 de Febrero del 2022.

MEMORANDUM N° 019 - 2022 -OIDC/HAL-C.

DE : Dr. JEAN CARLO FARAFN APARICIO.
JEFE DE LA OFICINA DE INVESTIGACIÓN, DOCENCIA y CAPACITACION.

A : DR. FREDY QUISPE TOCRE
JEFE DEL DEPARTAMENTO DE DIAGNOSTICO POR IMAGENES

ASUNTO : AUTORIZAR INGRESO DE ESTUDIANTES DE LA ESCUELA
PROFESIONAL DE MEDICINA HUMANA PARA OBTENER DATOS
PARA PROYECTO DE TESIS.

REF. : FUT N° 533- 2022

Mediante el presente me dirijo a Ud. Para hacer de su conocimiento, que los estudiantes Sharon Angélica Vargas Quisca y Pavel Edmundo Luna Mancilla estudiantes de la Facultad de Ciencias de la Salud de la Escuela Profesional de Medicina Humana de la Universidad Andina del Cusco, presentaron su documento solicitando el ingreso a las instalaciones del Servicio de Rayos X de nuestra Institución, para obtener dato para realizar su proyecto de tesis, por lo que solicito a su jefatura dar las facilidades del caso para que realice dicho trabajo. Se adjunta al presente el documento de la referencia.

Atentamente.

GOBIERNO REGIONAL CUSCO
GERENCIA REGIONAL DE SALUD - RUSCO
HOSPITAL ANTONIO LORENA
Jean Carlo Farfan Aparicio
Dr. Jean Carlo Farfan Aparicio
C.M.P. 438170 R.N.E. 031480
JEFE OFIC. INVEST. DOCENCIA Y CAP.

Cc. arch.
JCFA/cga

Victoria Román
c/20/02/2022



Captura de Pantalla de la Aplicación de IA

