UNIVERSIDAD NACIONAL DEL CAAGUAZÚ

FACULTAD DE CIENCIAS Y TECNOLOGÍAS

CARRERA DE INGENIERÍA EN INFORMÁTICA

RECONOCIMIENTO DE IMÁGENES APLICANDO DEEP LEARNING PARA EL APOYO AL DIAGNÓSTICO MÉDICO DE ENFERMEDADES RESPIRATORIAS EN RADIOGRAFÍAS DEL TÓRAX CON TECNOLOGÍA JETSON NANO EN EL SANATORIO SAN JOSÉ DE CORONEL OVIEDO

RODRIGO EMMANUEL AVALOS MELGAREJO

Coronel Oviedo - Paraguay

Año 2022

UNIVERSIDAD NACIONAL DEL CAAGUAZÚ

FACULTAD DE CIENCIAS Y TECNOLOGÍAS

CARRERA DE INGENIERÍA EN INFORMÁTICA

TÍTULO

RECONOCIMIENTO DE IMÁGENES APLICANDO DEEP LEARNING PARA EL APOYO AL DIAGNÓSTICO MÉDICO DE ENFERMEDADES RESPIRATORIAS EN RADIOGRAFÍAS DEL TÓRAX CON TECNOLOGÍA JETSON NANO EN EL SANATORIO SAN JOSÉ DE CORONEL OVIEDO

Elaborado por

RODRIGO EMMANUEL AVALOS MELGAREJO

Tutor

Ing. Víctor Manuel Melgarejo Riveros

Trabajo de Grado presentado a la Facultad de Ciencias y Tecnologías de la Universidad Nacional de Caaguazú, como requisito para la obtención del título de Ingeniero en Sistemas Informáticos.

Coronel Oviedo - Paraguay
2022

PÁGINA DE APROBACIÓN

MESA EXAMINADORA DE SUSTENTACIÓN DE TESIS DE GRADO

Carrera de Ingeniería en Informática

Título de la Tesis: RECONOCIMIENTO DE IMÁGENES APLICANDO DEEP LEARNING PARA EL APOYO AL DIAGNÓSTICO MÉDICO DE ENFERMEDADES RESPIRATORIAS EN RADIOGRAFÍAS DEL TÓRAX CON TECNOLOGÍA JETSON NANO EN EL SANATORIO SAN JOSÉ DE CORONEL OVIEDO.

Calificación Obtenida: _____

_____ Miembro

_____ Miembro

_____ Miembro

_____ Miembro

_____ Presidente

Acta Nº: _____

Fecha: _____

DEDICATORIA

Este Proyecto de tesis de Fin de Grado va dedicado a:

En primer lugar a Dios y a su hijo Jesús, por guiar mis pasos y bendecirme siempre, por ser mi guía espiritual y por haberme regalado a mi maravillosa familia y permitiéndome alcanzar uno de mis mayores metas de mi vida.

A los mejores padres Ramón Avalos y Gladys Melgarejo que me han dado la vida y enseñarme los verdaderos valores; y permitiéndome la formación de mi carrera universitaria y la fortaleza para seguir adelante en la culminación de mi título profesional.

A mi padrino Elvio Florentín que dejó huellas maravillosas no sólo en mi vida sino en la de toda mi familia, la persona que solo dejó recuerdos hermosos y únicos, estando a su lado era imposible no sonreír y estar tristes, por haberme considerado y cuidado como a una hijo más. ✝

A mis abuelos Bernardo Melgarejo y Emiliano Barrios por ser mis ángeles desde lo más alto y por haberme acompañado y guiado en los primeros años más importantes de mi vida mientras estuve a su lado. ✝

A toda mi familia que sin su apoyo y motivación de seguir siempre, batallar y nunca rendirme.

¡A todos y cada uno de ustedes eternamente agradecido!

AGRADECIMIENTO

A Dios y a Jesús por todas las bendiciones en mi vida.

A mis padres por ser mi guía y mi fortaleza en todo momento, por apoyarme en cada paso que doy, por ser mi ejemplo a seguir, por ayudarme a luchar por mis sueños y demostrarme que nada es imposible, que con esfuerzo y con la fe puesta en Dios se pueden alcanzar los objetivos. Nunca me falten.

A mis familiares, por brindarme su apoyo incondicional, por acompañarme de cerca en todo momento y por brindarme todo su cariño y amor.

A mi tutor, el Ingeniero Víctor Melgarejo por su orientación y por guiarme durante el proceso de elaboración de esta tesis, por todo el tiempo dedicado, la paciencia y la enseñanza que hicieron posible culminar con éxito este proyecto.

Al ing. Héctor Estigarribia y Julio Coronel por haberme brindado gran ayuda, orientación y recomendaciones para la culminación de mi proyecto.

Al Ing. Juan Vicente por su orientación, consejos, predisposición y revisiones para culminar con exactitud. Un capo total.

A todos mis maestros que mediante todos sus conocimientos me hicieron crecer profesionalmente.

A mis compañeros de lucha, por su apoyo, por las enseñanzas y experiencias que compartimos estos años de formación profesional, por las aventuras, compañía de cada día, risas y ser mi soporte en todo momento.

A mis amigos quienes estuvieron siempre conmigo en los buenos y malos momentos, con quienes compartí los mejores años de mi vida y de quienes guardo los mejores recuerdos.

Al Dr. Denis Figueredo por el apoyo, la paciencia, amabilidad y la ayuda médica indispensable para la toma de decisión y elaboración de este proyecto para la medicina.

Agradecido con todas estas gratas personas que hicieron que todo esto sea posible

RECONOCIMIENTO DE IMÁGENES APLICANDO DEEP LEARNING PARA EL APOYO AL DIAGNÓSTICO MÉDICO DE ENFERMEDADES RESPIRATORIAS EN RADIOGRAFÍAS DEL TÓRAX CON TECNOLOGÍA JETSON NANO EN EL SANATORIO SAN JOSÉ DE CORONEL OVIEDO.

RESUMEN

La implementación de algoritmos de inteligencia artificial para el apoyo a las tomas de decisiones clínicas por medio de las radiografías del tórax enfrenta desafíos con confiabilidad e interpretabilidad, establecemos una herramienta tecnológica de diagnóstico médico basada en Deep Learning para la clasificación de pacientes con enfermedades respiratorias o normales que son reconocidas las imágenes por la red neuronal que puede ayudar a acelerar el diagnóstico lo que facilita un tratamiento más rápido y mejora los resultados clínicos.

La inteligencia artificial y la medicina siguen un camino paralelo durante las últimas décadas, con el Deep Learning y especialmente las redes neuronales profundas son ideales para el reconocimiento de patrones, aprenden directamente a partir de los datos y ayudan a resolver problemas complejos, se ha aplicado ampliamente en aplicaciones de procesamiento de imágenes y visión por computadora en la salud, debido a la buena precisión en las tareas de clasificación de imágenes. El modelo de aprendizaje se ejecuta en el Jetson Nano que ofrece el poder de cómputo necesario para el campo y proporciona los resultados acelerados en una plataforma compacta esencial para el entrenamiento.

Palabras clave: inteligencia artificial, radiografías del tórax, diagnóstico médico, deep learning, enfermedades respiratorias, reconocimiento de imágenes, redes neuronales profundas, clasificación de imágenes, precisión, modelo de aprendizaje, Jetson Nano.

IMAGE RECOGNITION APPLYING DEEP LEARNING TO SUPPORT THE DIAGNOSIS MEDICAL OF RESPIRATORY DISEASES IN CHEST X-RAYS USING JETSON NANO TECHNOLOGY AT THE SANATORIUM SAN JOSÉ CORONEL OVIEDO.

ABSTRACT

The implementation of artificial intelligence algorithms to support clinical decision making through chest radiographs faces challenges with reliability and interpretability, we establish a technological tool for medical diagnosis based on Deep Learning for the classification of patients with respiratory diseases or normal images that are recognized by the neural network that can help speed up diagnosis, facilitating faster treatment and improving clinical outcomes.

Artificial intelligence and medicine follow a parallel path during the last decades, with Deep Learning and especially deep neural networks are ideal for pattern recognition, they learn directly from data and help solve complex problems, it has been applied widely used in image processing and computer vision applications in healthcare, due to good accuracy in image classification tasks. The learning model runs on the Jetson Nano which offers the computing power needed for the field and delivers the accelerated results in a compact platform essential for training.

Keywords: artificial intelligence, chest X-rays, medical diagnosis, deep learning, respiratory diseases, image recognition, deep neural networks, image classification, accuracy, model learning, Jetson Nano.

ÍNDICE DE CONTENIDO

DEDICATORIA I

AGRADECIMIENTO II

RESUMEN IV

ABSTRACT V

ÍNDICE DE CONTENIDO VI

ÍNDICE DE TABLAS XIII

ÍNDICE DE FIGURAS XIV

INTRODUCCIÓN 16

CAPÍTULO I 18

1. MARCO INTRODUCTORIO 18

1.1. PLANTEAMIENTO Y FORMULACIÓN DEL PROBLEMA 18

1.2. DELIMITACIÓN Y ALCANCE 20

1.3. OBJETIVOS 21

1.3.1. OBJETIVO GENERAL 21

1.3.2. OBJETIVOS ESPECÍFICOS 21

1.4. JUSTIFICACIÓN 22

CAPÍTULO II 23

2. MARCO TEÓRICO 23

2.1. ANTECEDENTES DE LA INVESTIGACIÓN 23

2.2. BASES TEÓRICAS 26
2.2.1. Inteligencia artificial 26
2.2.1.1. Historia 26
2.2.1.2. Funcionamiento 27
2.2.1.3. Subcampos principales 27
2.2.1.4. Flujo de trabajo 29
2.2.1.4.1. Preparación de los datos 29
2.2.1.4.2. Modelado de IA 29
2.2.1.4.3. Simulación y test 30
2.2.1.4.4. Implementación 30
2.2.2. Redes Neuronales 31
2.2.2.1. Funcionamiento 32
2.2.3. Deep Learning 34
2.2.3.1. Requerimientos 34
2.2.3.1.1. Potencia de cálculo 34
2.2.3.1.2. Datos etiquetados 35
2.2.3.2. Funcionamiento 35
2.2.3.2.1. Representación de características 36
2.2.3.2.2. Capas de aprendizaje profundo 36
2.2.3.2.3. Resultados del aprendizaje profundo 36
2.2.3.3. Redes neuronales profundas 37
2.2.3.3.1. Redes neuronales convolucionales 37

2.2.3.4. Reconocimiento de imágenes 40
2.2.4. Visión por computadora 40
2.2.4.1. Funcionamiento 41
2.2.4.1.1. Adquirir una imagen 41
2.2.4.1.2. Procesando la imagen 41
2.2.4.1.3. Entendiendo la imagen 41
2.2.4.1.4. Clasificación de imágenes 41
2.2.5. Procesamiento digital de imágenes 42
2.2.6. Edge Computing 43
2.2.6.1. Edge computing con Jetson Nano 43
2.2.6.1.1. Entrenamiento 43
2.2.6.1.2. Inferencia 43
2.2.7. Enfermedades respiratorias 44
2.2.7.1. Neumonía 45
2.2.7.1.1. Neumonía Bacteriana 46
2.2.7.1.2. Neumonía Viral 46
2.2.7.1.3. Covid-19 47
2.2.7.1.4. Tuberculosis 47
2.2.7.2. Diagnóstico médico 48
2.2.7.2.1. Radiografía del tórax 49
2.2.7.3. Razones 50
CAPÍTULO III 51

3. MARCO METODOLÓGICO 51
3.1. TIPO DE INVESTIGACIÓN 51
3.2. NIVEL DE INVESTIGACIÓN 51
3.3. TÉCNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS . 52
3.3.1. Kaggle 52
3.3.1.1. Base de datos 52
3.3.1.1.1. Base de datos de radiografías de Covid-19 53
3.3.1.1.2. Base de datos de rayos X del tórax Tuberculosis 54
3.4. DESCRIPCIÓN DE LOS PROCEDIMIENTOS DE ANÁLISIS DE DATOS 55
3.4.1. Preparación del conjunto de datos 55
3.4.2. Aprendizaje por Transferencia 57
3.4.3. Entrenamiento del modelo 58
3.4.3.1. Métricas de entrenamiento 58
3.4.3.1.1. Épocas 59
3.4.3.1.2. Time 59
3.4.3.1.3. Data 59
3.4.3.1.4. Loss 59
3.4.3.1.5. Acc@1 59
3.4.3.2. Entrenamientos de modelos realizados 60
3.4.4. Precisión del modelo en el entrenamiento 61
3.4.4.1. Conversión del modelo a ONNX 62

3.5. POBLACIÓN Y MUESTRA 64
3.5.1. Criterios de inclusión 64
3.5.2. Criterios de exclusión 64
3.6. CONSIDERACIONES ÉTICAS 64
CAPÍTULO IV 65
4. MARCO ANALÍTICO 65
4.1. PRESENTACIÓN Y ESTUDIO DE LOS RESULTADOS 65
4.1.1. Procesamiento de imágenes con TensorRT 65
4.1.2. Resultados de test del conjunto de datos 69
4.1.2.1. Diagnósticos Covid-19 69
4.1.2.2. Diagnósticos neumonía bacteriana 70
4.1.2.3. Diagnósticos neumonía viral 71
4.1.2.4. Diagnósticos tuberculosis 72
4.1.2.5. Diagnósticos normal 73
4.1.3. Procesamiento de video en tiempo real 74
4.1.3.1. Demostración de reconocimiento en cámara 74
4.2. CONSTRUCCIÓN DEL SOFTWARE 75
4.2.1. Recurso Tecnológico 75
4.2.1.1. Jetson Nano 75
4.2.1.1.1. Nvidia Jetson 76
4.2.1.1.2. Especificaciones técnicas 76
4.2.1.1.3. JetPack 77

4.2.2. Herramientas Utilizadas 78
4.2.2.1. BalenaEtcher 78
4.2.2.2. Linux 78
4.2.2.3. Jetson Inference 78
4.2.2.4. Python 78
4.2.2.4.1. Argparse 78
4.2.2.4.2. Gooey 79
4.2.2.5. Visual Studio Code 79
4.2.2.6. Software de aprendizaje profundo 79
4.2.2.6.1. Cuda 79
4.2.2.7. Frameworks de Deep Learning 79
4.2.2.7.1. PyTorch 80
4.2.2.7.2. ONNX 80
4.2.2.8. Entrenamiento de Deep Learning 80
4.2.2.8.1. Dali 80
4.2.2.8.2. CuDNN 81
4.2.2.8.3. TAO Toolkit 82
4.2.2.9. Inferencia de aprendizaje profundo 82
4.2.2.9.1. TensorRT 82
4.2.2.10. OpenGL 83
4.2.3. PRUEBA DE LA APLICACIÓN 84
4.2.3.1. Manual del usuarios 84

4.2.3.1.1. Interfaz Gráfica 84
4.2.4. RECURSOS ECONÓMICOS 90
4.2.4.1. Costo de Inversión 90
CAPÍTULO V 91
RESULTADOS 91
CONCLUSIONES 92
RECOMENDACIONES 94
Bibliografía 95
ANEXO 101
ANEXO 1 101
Nota de solicitud 101
ANEXO 2 102
Área de Radiografía 102
ANEXO 3 104
Área de Servicio de Diagnóstico por imágenes 104
ANEXO 4 105
Disco RX de Tórax de paciente 105
ANEXO 5 107
Imágenes de radiografías del Tórax de Pacientes del sanatorio. 107
ANEXO 6 109
Jetson nano y componentes de desarrollo. 109

ÍNDICE DE TABLAS

Tabla 1. Tipos de enfermedades virus y bacterias 48
Tabla 2. Estructura de la 1ra base de datos radiografías del tórax 53
Tabla 3. Estructura de la 2da base de datos radiografías del tórax 54
Tabla 4. Preparación del conjunto de datos 56
Tabla 5. Entrenamientos de modelos realizados 60
Tabla 6. Diagnósticos de Test de Covid-19 69
Tabla 7. Diagnósticos de Test de Neumonía Bacteriana 70
Tabla 8. Diagnósticos de Test de Neumonía Viral 71
Tabla 9. Diagnósticos de Test de Tuberculosis 72
Tabla 10. Diagnósticos de Test de Normal 73
Tabla 11. Especificaciones técnicas del Jetson Nano 77
Tabla 12. Recursos Tecnológicos 90
Tabla 13. Resultados de Diagnóstico médico de la muestra 91

ÍNDICE DE FIGURAS

Figura 1. Historia de la Inteligencia Artificial 27
Figura 2. Los pasos para un flujo de trabajo completo de la IA 29
Figura 3. Origen de las redes neuronales..... 31
Figura 4. Una red neuronal 32
Figura 5. Cómo funciona el Deep Learning 36
Figura 6. Arquitectura de DNN con múltiples capas 37
Figura 7. Una red neuronal con muchas capas convolucionales..... 38
Figura 8. Funcionamiento de la visión por computadora 41
Figura 9. Radiografías de tórax en pacientes con neumonía y normal 46
Figura 10. Base de datos de radiografía de covid-19 53
Figura 11. Base de datos de rayos X de Tuberculosis..... 54
Figura 12. Gráfica de partición del conjunto de datos..... 55
Figura 13. Aprendizaje por transferencia 57
Figura 14. Entrenamiento del modelo en la terminal..... 58
Figura 15. Gráfica de entrenamiento del modelo de Deep Learning..... 61
Figura 16. Modelo de Deep Learning..... 62
Figura 17. Proceso de conversión del modelo de Deep Learning 62
Figura 18. Modelo de Deep Learning a formato ONNX 63
Figura 19. Línea de comandos para el diagnóstico médico 1 65
Figura 20. Diagnóstico médico por línea de comandos 1 66
Figura 21. Diagnóstico médico con un 99.69% de Covid-19 66
Figura 22. Línea de comandos para el diagnóstico médico 2 67
Figura 23. Diagnóstico médico por línea de comandos 2 67
Figura 24. Diagnóstico médico con un 61.85% de N. Bacteriana 68
Figura 25. Resultados de diagnóstico del test de covid-19..... 69
Figura 26. Resultados de diagnóstico del test de neumonía bacteriana.. 70
Figura 27. Resultados de diagnóstico del test de neumonía viral 71
Figura 28. Resultados de diagnóstico del test de neumonía viral 72
Figura 29. Resultados de diagnóstico del test de normal 73

Figura 30. Diagnóstico por cámara de video 1 74
Figura 31. Diagnóstico por cámara de video 1 74
Figura 32. NVIDIA Jetson Nano..... 75
Figura 33. PyTorch biblioteca de tensores para GPU. 80
Figura 34. Biblioteca de carga de datos Dali 81
Figura 35. cuDNN biblioteca de primitivas con aceleración de GPU 81
Figura 36. TAO Toolkit..... 82
Figura 37. TensorRT optimizador de inferencia..... 83
Figura 38. La interfaz gráfica de usuario..... 84
Figura 39. Ingresar la imagen de rayos x del paciente. 85
Figura 40. Carga de ingreso de la imagen..... 86
Figura 41. Guardar la imagen para el diagnóstico 87
Figura 42. Carga de guardar la imagen 87
Figura 43. Ejecución y resultado por interfaz gráfica del software. 88
Figura 44. Resultado del Diagnóstico Médico en imagen. 89
Figura 45. Diagnóstico Médico del paciente impreso en la imagen. 89
Figura 46. Nota de solicitud al sanatorio..... 101
Figura 47. Área de Radiografía 1..... 102
Figura 48. Área de Radiografía 2..... 102
Figura 49. Área de Radiografía 3..... 103
Figura 50. Área de Radiografía 4..... 103
Figura 51. Servicio de Diagnóstico por imágenes - 1..... 104
Figura 52. Servicio de Diagnóstico por imágenes - 2..... 104
Figura 53. Disco RX de Tórax PA - 1..... 105
Figura 54. Disco RX de Tórax PA - 2..... 105
Figura 55. Imagen de rayos X de Tórax del paciente 106
Figura 56. Radiografía del tórax frontal..... 107
Figura 57. Radiografía del tórax paciente acostado..... 107
Figura 58. Radiografía del tórax paciente sentado 108
Figura 59. Equipos de desarrollo 109

INTRODUCCIÓN

Las enfermedades respiratorias se clasificaron como la cuarta causa principal de mortalidad a nivel mundial según la organización mundial de la salud, la neumonía afecta tanto en niños como en personas mayores de edad donde la causa de infección son los virus y bacterias. La disponibilidad de servicios para diagnosticar y tratar enfermedades son clave, actualmente la atención médica al paciente se realiza de forma manual en diversos servicios por parte del médico, sin ninguna intervención de tecnología informática. Se han ido ampliando la utilización de las tecnologías de la información y comunicación durante los últimos años con los avances de inteligencia artificial ha evolucionado para brindarnos beneficios y complementar las capacidades en todas las áreas, se emplean para la solución de los problemas, los algoritmos inteligentes son clave para identificar patrones, entender sistemas complejos y optimizar escenarios únicos.

El deep learning un subcampo de la inteligencia artificial utiliza redes neuronales profundas son ideales para ayudar a resolver problemas complejos en situaciones de la vida real, aprenden directamente a partir de los datos las relaciones entre entradas y salidas que no son lineales, hacen generalizaciones e inferencias, revelan patrones y modela datos altamente volátiles necesarias para clasificar eventos. Como resultado las redes neuronales pueden mejorar los procesos de decisión en áreas como la medicina en el diagnóstico médico, mediante el procesamiento de imágenes y visión por computadora reconociendo en las radiografías del tórax las enfermedades respiratorias padecidas por el paciente. En este proyecto estaré clasificando las siguientes enfermedades respiratorias que son la neumonía por bacterias y virus, covid-19 y la tuberculosis,.

Los modelos de inteligencia artificial basado en deep learning se ejecutan en dispositivos edge computing que proporcionan los resultados rápidos necesarios en el campo el cual utilizaremos el Jetson nano un kit de desarrollo que ofrece el poder de cómputo necesario en una plataforma compacta con sistema operativo linux basado en Ubuntu con gráficos acelerados para mejorar significativamente la velocidad, precisión del modelo y con un muy bajo consumo de energía.

Partiendo de este enfoque el presente Proyecto de Fin de Grado se encuentra estructurado de la siguiente manera:

Capítulo I, se describe el planteamiento del problema, los objetivos Generales y específicos, la justificación y el alcance del proyecto.

Capítulo II, se expone el Marco Teórico con la descripción de los antecedentes de la investigación, las bases teóricas que sustentan teóricamente el Proyecto de Fin de Grado.

Capítulo III, se presenta el Marco Metodológico en él que se describen el tipo y nivel de la investigación, la población y muestra de estudio, además las técnicas e instrumentos utilizados para la recolección de datos y las descripciones de los procedimientos de análisis de datos, y las consideraciones del Proyecto de fin de Grado.

Capítulo IV, presenta el Marco Analítico, que comprende la Presentación y estudios de los resultados, la construcción del software con los recursos tecnológicos y herramientas utilizadas, Prueba de la aplicación y Recursos económicos.

Capítulo V, en este capítulo se muestran los resultados, Conclusiones y Recomendaciones, Además de las referencias bibliográficas, los apéndices y los anexos.

CAPÍTULO I

1. MARCO INTRODUCTORIO

1.1. PLANTEAMIENTO Y FORMULACIÓN DEL PROBLEMA

Ante el aumento de las enfermedades respiratorias que afectan nuestro sistema respiratorio y actualmente con el nuevo virus del coronavirus las tasas de infecciones han aumentado exponencialmente con los síntomas y transmisiones provocando inconvenientes en el diagnóstico médico en relación de otras enfermedades respiratorias que ya existían anteriormente, en consecuencia ha sobrecargado y complicado el trabajo de los profesionales de la salud.

El procedimiento una vez que el paciente se encuentra en estado de salud reservado por problemas respiratorios, el médico solicita la realización del test de hisopado PCR método que se utiliza de referencia para el diagnóstico del covid-19, sin embargo, la técnica es manual, laboriosa y requiere mucho tiempo para el resultado, lo que podría ser crucial para el paciente en estado grave. Posteriormente a la vez se le realiza el examen de radiografía del tórax/pulmón, que es una herramienta de fácil acceso y rápida, que se utiliza para ver las infecciones que padecen en los pulmones. Las imágenes radiográficas pueden ayudar a la detección de los casos de enfermedades, actualmente por la pandemia la mayoría de los casos son de covid-19 o se tiende a ello en el diagnóstico, la problemática resalta que en los resultados los casos tienen características similares con otras enfermedades respiratorias, suelen haber imágenes de varias neumonías virales o bacterianas idénticas que suelen ser relacionadas y se superponen con otras enfermedades, lo que puede conducir a un diagnóstico equivocado que puede llevar a una neumonía viral más aguda con el tiempo, y por lo tanto retrasa el tratamiento del paciente o en situaciones podría tener resultado fatal.

En consecuencia, es complicado y tedioso para los profesionales de la salud, ya sea radiólogos, neumólogos y médicos distinguir de estas enfermedades respiratorias en los imágenes de rayos X del tórax para elaborar un diagnóstico correcto, por lo que se plantea la implementación de una herramienta tecnológica basada en inteligencia artificial para el apoyo a la toma de decisiones clínicas utilizando las radiografías del tórax para el reconocimiento de las imágenes por medio de redes neuronales.

El reconocimiento de imágenes mediante visión por computadora utilizando redes neuronales profundas ayuda a contribuir a agilizar el diagnóstico y la clasificación de pacientes con enfermedades respiratorias. Varios estudios se han realizado al respecto destacándose el de Santamaría [1], quién habla de las redes neuronales convolucionales para resolver igual número de problemas de clasificación de patrones asociados con enfermedades, se utilizan diferentes tipos de imágenes médicas como: imágenes de resonancias magnéticas del cerebro para identificar tumores cerebrales, tomografías de tórax para la identificación de tipos de tuberculosis y las radiografías del tórax para la detección de neumonía. La mayoría de estos trabajos se concentran en el aspecto científico de las técnicas de reconocimiento de imágenes con fines médicos, sin embargo en este proyecto se propone la implementación de dichas técnicas mediante un equipo de hardware de bajo costo y una interfaz gráfica de usuario amigable que pueda ser utilizada por el personal de la salud sin un entrenamiento especializado en computación.

1.2. DELIMITACIÓN Y ALCANCE

El sanatorio San José de la ciudad de Coronel Oviedo un centro de atención médica ubicada en la ciudad de Coronel Oviedo, son una institución encargado del cuidado de la salud, basados en la calidad humana y la eficiencia a través del alto desarrollo de la tecnología, cuenta con clínica médica, medicina general y familiar, cirugía general, pediatría, neumología, electrocardiografía, especialista en imagen, ecografía, consultas e internaciones entre otros.

La medicina es indispensable teniendo la necesidad de contar con el apoyo de la tecnología que puedan ayudar a realizar el mayor cumplimiento de objetivos para reforzar la toma de decisión de qué enfermedad padecen los pacientes, los sistemas inteligentes se transforman en una destacada herramienta para aportar con sus estudios, por lo tanto partiendo de las necesidades.

El alcance de este proyecto es el de implementar un software con inteligencia artificial basado en deep learning para el apoyo al diagnóstico médico de pacientes con enfermedades respiratorias mediante imágenes radiográficas del tórax/pulmón para la toma de decisiones clínicas que serán reconocidas por las redes neuronales y acelerar los resultados, lo que beneficia un tratamiento más rápido y eficiente, mejora la atención médica del sanatorio.

El modelo de Deep Learning está entrenado para clasificar cinco clases que son el covid-19, la neumonía Bacteriana, neumonía Viral, Tuberculosis y normal. Cada diagnóstico médico se imprime en la imagen con su porcentaje de exactitud para el sanatorio. Es importante mencionar se puede agregar otras enfermedades respiratorias, luego para entrenar y ajustar un modelo deep learning más robusto.

1.3. OBJETIVOS

1.3.1. OBJETIVO GENERAL

Implementar un modelo de inteligencia artificial basado en Deep Learning para la clasificación de enfermedades respiratorias en radiografías del tórax por medio de redes neuronales profundas en el Sanatorio San José.

1.3.2. OBJETIVOS ESPECÍFICOS

- Identificar las enfermedades respiratorias que pueden ser clasificadas mediante imágenes radiográficas del tórax y el proceso clínico.
- Ajustar un modelo de Deep Learning robusto que pueda tomar decisiones de apoyo precisas.
- Optimizar el tiempo de respuesta al diagnóstico médico.
- Crear una interfaz gráfica de carga de imágenes de rayos X a los profesionales de la salud para generar el diagnóstico del paciente.

1.4. JUSTIFICACIÓN

El presente proyecto de investigación pretende implementar un software basado en inteligencia artificial aplicando deep learning para la clasificación de pacientes con enfermedades respiratorias en las radiografías del tórax que son reconocidas por las redes neuronales profundas que sirvan de apoyo del diagnóstico médico en el sanatorio San José de Coronel Oviedo.

El objeto de estudio de este trabajo son enfoques basados en deep learning para comprender la infección y elaborar una herramienta tecnológica para los profesionales de la salud para tener una segunda opinión digital que confirme su evaluación de la condición de salud de un paciente, les daría una ventaja y les permitiría actuar con más confianza, mientras esperan el análisis de un radiólogo, el software generará un diagnóstico de apoyo en donde evalúa con porcentajes de exactitud para considerar y usar en sus estudios a la toma de decisiones clínicas y facilite un tratamiento más rápido, a su vez administrar los diagnósticos oportunos para pacientes en estado de auxilio.

De todo lo expuesto, con la realización de este proyecto de fin de grado el sanatorio se beneficiará debido a que mejorará la calidad del servicio y atención médica, cuidado de salud del paciente, reducir el tiempo de evaluación del diagnóstico, respuesta médica inmediata con asistencia informática y realizar los tratamientos a la enfermedad que padece el paciente.

CAPÍTULO II

2. MARCO TEÓRICO

2.1. ANTECEDENTES DE LA INVESTIGACIÓN

Según Santamaría [1] manifiesta en su tesis de maestría en ciencias de la computación titulado “Reconocimiento de patrones en imágenes médicas por medio de redes neuronales convolucionales”, que las imágenes médicas digitalizadas permiten la detección, diagnóstico y tratamiento de enfermedades. Las imágenes médicas macroscópicas son aquellas imágenes obtenidas por medio de radiación ionizada o magnetismo, las cuales permiten la identificación de órganos y estructuras del cuerpo. En los últimos años la aplicación de diversas herramientas computacionales como: bases de datos, procesamiento distribuido, procesamiento digital de imágenes y reconocimiento de patrones en imágenes médicas digitales han contribuido en la creación de Diagnósticos Asistidos por Computadora o también conocidos como CAD (Computer Aided Diagnosis), los cuales sirven como una herramienta auxiliar en el cuidado de la salud. Esta tesis plantea utilizar diversas arquitecturas basadas en Redes Neuronales Convolucionales (CNN por sus siglas en inglés) para la identificación automática de enfermedades en imágenes médicas.

En su trabajo se describen tres arquitecturas de CNN para resolver igual número de problemas de clasificación o detección de patrones asociados con enfermedades, se utilizan diferentes tipos de imágenes médicas como: imágenes de resonancias magnéticas del cerebro para identificar tumores cerebrales, tomografías de tórax para la identificación de tipos de tuberculosis y radiografías del tórax para la detección de neumonía. Finalmente se propone un algoritmo de registro automático de las regiones que corresponden al tórax que identifica intrínsecamente la traslación, escala y rotación que alinean las regiones del tórax en imágenes de rayos X.

Según Huamaní [2] manifiesta en su tesis de grado titulado “sistema experto de apoyo para el proceso de diagnóstico de enfermedades respiratorias en la clínica San Bartolomé sac”, que el objetivo principal del presente trabajo de investigación es crear un sistema experto de apoyo para el proceso de diagnóstico de enfermedades respiratorias, del cual será usado inicialmente por el médico del área de Neumología de la clínica San Bartolomé, para brindar la actividad de la atención de manera fluida e inmediata las consultas de los pacientes. El problema principal que presenta la clínica es la cantidad de personal médico; en este caso uno por turno lo que ocasiona la demora en la atención, la atención observada durante 11 días muestra una cantidad de 545 pacientes, caso que se complica por la falta de un apoyo de un sistema informático de apoyo en lo que se refiere al proceso de diagnósticos de los pacientes. El trabajo de investigación se desarrollará con la finalidad de reducir tiempo de la atención y reducir el tiempo de la evaluación del diagnóstico siendo el sistema experto utilizado en la clínica y valorar el cumplimiento de la reducción de sus tiempos de sus servicios que se utiliza en este sistema. Al implementar el sistema experto de apoyo para el proceso de diagnósticos facilitará a la clínica aumentar el número de atenciones diarias y agilizar el proceso de atención para el área de Neumología.

Según los autores [3] de una Conferencia Internacional manifiesta en su documento “Diagnóstico de enfermedades basado en aprendizaje profundo utilizando clasificación de imágenes”, que cualquier enfermedad sea curable o no, debe ser diagnosticada adecuadamente con un tiempo en la mano para tomar las acciones oportunas. Como se dice popularmente, la detección temprana de cualquier enfermedad está medio curada. Para la detección de enfermedades como Neumonía, Covid-19, Radiografía de Tumor Cerebral, Tomografía Computarizada son una técnica popularmente utilizada en la actualidad. La motivación para el estudio del tema fue que debido a la densidad poblacional de nuestro país, se expuso la vulnerabilidad de infectarse y no ser bien tratado durante el

brote de Covid-19. La proporción de médicos en India es de casi 1:1456, lo que significa que 1 médico tiene aproximadamente 1456 pacientes que atender. Eso también da como resultado que se desperdicie mucho tiempo en el diagnóstico, la programación de citas, la recopilación de informes, etc., lo que podría resultar crítico para un paciente. Para reducir todo el tiempo perdido, con la ayuda del aprendizaje automático pretendemos saber si podemos predecir si el paciente está infectado con una determinada enfermedad o no. Cómo lo hacemos es mediante el uso de modelos de aprendizaje profundo y el análisis sobre la base de algunos escaneos de rayos X del tórax para detectar neumonía.

2.2. BASES TEÓRICAS

2.2.1. Inteligencia artificial

La inteligencia artificial (IA) hace posible que las máquinas aprendan de la experiencia, se ajusten a nuevas aportaciones y realicen tareas como seres humanos. La mayoría de los ejemplos de inteligencia artificial sobre los que oye hablar hoy en día, desde computadoras que juegan ajedrez, hasta automóviles de conducción autónoma, recurren mayormente al deep learning y al procesamiento del lenguaje natural. Empleando estas tecnologías, las computadoras pueden ser entrenadas para realizar tareas específicas procesando grandes cantidades de datos y reconociendo patrones en los datos. [4]

La inteligencia artificial es una simulación o imitación de los procesos de inteligencia humana realizada por sistemas informáticos, se puede decir que se trata de sistemas automatizados que generan respuestas en base a los datos de entrada que reciben de un modelo creado a partir de un periodo de formación o estudio, diseñado para percibir su entorno, entender su comportamiento y realizar acciones de los ha sido capacitado.

2.2.1.1. Historia

El término inteligencia artificial fue adoptado en 1956, pero se ha vuelto más popular hoy día gracias al incremento en los volúmenes de datos, algoritmos avanzados, y mejoras en el poder de cómputo y el almacenaje. La investigación inicial de la inteligencia artificial en la década de 1950 exploraba temas como la solución de problemas y métodos simbólicos. En la década de 1960, el Departamento de Defensa de los Estados Unidos mostró interés en este tipo de trabajo y comenzó a entrenar computadoras para que imitaran el razonamiento humano básico. Por ejemplo, la Defense Advanced Research Projects Agency (DARPA, Agencia de Proyectos de Investigación Avanzada de Defensa) realizó proyectos de planimetría de calles en la década de 1970. Y DARPA produjo

asistentes personales inteligentes en 2003, mucho tiempo antes que Siri, Alexa o Cortana fueran nombres comunes. [4]

Este trabajo inicial abrió el camino para la automatización y el razonamiento formal que vemos hoy en las computadoras, incluyendo sistemas de soporte a decisiones y sistemas de búsqueda inteligentes que pueden ser diseñados para complementar y aumentar las capacidades humanas. La inteligencia artificial ha evolucionado para brindar muchos beneficios específicos a todas las industrias.

Figura 1. Historia de la Inteligencia Artificial

2.2.1.2. Funcionamiento

La inteligencia artificial funciona combinando grandes cantidades de datos con procesamiento rápido e iterativo y algoritmos inteligentes, permitiendo al software aprender automáticamente patrones o características en los datos. [4]

2.2.1.3. Subcampos principales

La inteligencia artificial es un vasto campo de estudio que incluye muchas teorías, métodos y tecnologías, además de los siguientes subcampos principales: el aprendizaje automático (Machine Learning), aprendizaje profundo (Deep Learning), cómputo cognitivo, visión por computadora, procesamiento del lenguaje natural (NLP). [4]

En este proyecto de tesis los subcampos de la inteligencia artificial que utilizaré son el Deep Learning y visión por computadora.

Además, varias tecnologías habilitan y dan soporte a la inteligencia artificial [4]:

- Unidad de procesamiento gráfico (GPU) son fundamentales para la inteligencia artificial porque aportan gran poder de cómputo requerido para el procesamiento iterativo. Entrenar redes neuronales requiere cantidad masiva de datos, además de poder de cómputo.

- Internet de las Cosas (IoT) genera cantidades masivas de datos de dispositivos conectados, la mayoría de ellos no analizados. La automatización de modelos con inteligencia artificial nos permite usar una mayor parte de ellos.

- Se están desarrollando algoritmos avanzados y se combinan en nuevas formas para analizar más datos con mayor rapidez y en múltiples niveles. Este procesamiento inteligente es clave para identificar y anticipar eventos poco comunes, entender sistemas complejos y optimizar escenarios únicos.

- Las APIs, o interfaces de programación de aplicaciones, son paquetes portables de código que hacen posible agregar funcionalidad de inteligencia artificial a productos y paquetes de software existentes. [4]

El objetivo de la inteligencia artificial y de este proyecto consiste en proveer software que pueda razonar lo que recibe y explicar lo que produce como resultado de lo que está capacitado. La inteligencia artificial proporcionará interacciones similares a las humanas y ofrecerá soporte a las decisiones para tareas específicas, pero no es sustituto de los humanos, y no lo será en el futuro cercano, están diseñados para el apoyo y solución de problemas.

2.2.1.4. Flujo de trabajo

Hay cuatro pasos para el flujo de trabajo completo impulsado por la IA, cada uno de los cuales desempeña su propio papel crítico en la implementación exitosa en un proyecto. [5]

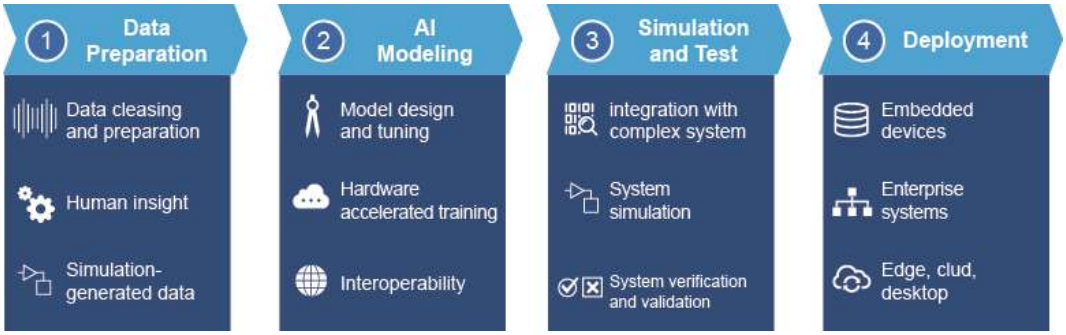

Figura 2. Los pasos para un flujo de trabajo completo de la IA

2.2.1.4.1. Preparación de los datos

Este es el momento más importante en el flujo de trabajo de la IA y seguramente, uno de los que más tiempo consumen. Sin datos sólidos y precisos, para utilizarlos como entrada y entrenar un modelo, la probabilidad de que los proyectos fracasen es mucho más elevada. Cuando los modelos de Deep Learning no funcionan como se esperaba, se tiende a tratar de corregirlos centrándose en cómo mejorar el modelo ajustando los parámetros o realizando múltiples iteraciones de entrenamiento. Sin embargo, habría que poner el foco en los datos de entrada; preprocesar y garantizar su limpieza y correcto etiquetado.

2.2.1.4.2. Modelado de IA

Una vez que los datos están limpios y correctamente etiquetados, es el momento de pasar a la fase de modelización del flujo de trabajo, que es donde se utilizan como entrada para que el modelo aprenda de ellos. El objetivo es crear un modelo sólido que pueda tomar decisiones inteligentes basadas en los datos y, sobre todo, en nuevos datos no vistos. Los modelos de IA pueden utilizar el Deep Learning, el Machine Learning o una combinación de ambos para buscar el resultado más preciso. La

modelización de la IA es un paso iterativo dentro del flujo de trabajo completo, y es importante hacer un seguimiento de los cambios que se realizan en el modelo a lo largo de este paso. Este seguimiento, junto con el registro de las iteraciones de entrenamiento, ayuda a explicar los parámetros que conducen al modelo más preciso y a crear resultados reproducibles.

2.2.1.4.3. Simulación y test

Los modelos de IA existen dentro de un sistema más amplio y deben funcionar en concierto con todas las demás piezas. La simulación y las pruebas son fundamentales antes de desplegar un modelo en el mundo real, ya que permiten validar que el modelo funciona correctamente y que interactúa de forma adecuada con otros sistemas. La confianza en el modelo llega después de haber simulado y probado con éxito todos los casos que deberá gestionar, y cuando se pueda verificar que funciona según lo previsto.

2.2.1.4.4. Implementación

Una vez que está listo para la implementación, el siguiente paso es elegir el hardware de destino y preparar el modelo en el lenguaje final en el que se implementará. Este paso suele requerir que los ingenieros de diseño compartan un modelo listo para la implementación, lo que les permite adaptar ese modelo al entorno de hardware designado.

Los modelos de IA se deben implementar en las CPU, GPU y/o FPGA de su producto final, ya sea que formen parte de un dispositivo embebido o edge, un sistema empresarial o la nube. Los modelos de IA que se ejecutan en el dispositivo embebido o edge proporcionan los resultados rápidos necesarios en el campo, mientras que los modelos de IA que se ejecutan en los sistemas empresariales y en la nube proporcionan resultados de los datos recopilados a través de muchos dispositivos. Con frecuencia, los modelos de IA se implementan en una combinación de estos sistemas. [6]

El proceso de despliegue se acelera cuando se genera código a partir de los modelos de IA y se ajusta a los dispositivos, mediante técnicas de optimización de generación de código y librerías optimizadas para el hardware, se puede ajustar el código para que se adapte al perfil de bajo consumo requerido por los dispositivos embebidos y edge.

El dispositivo embebido o edge computing donde se va a implementar el modelo de IA es el Jetson Nano que cuenta con una potente GPU Maxwell de 128 núcleos, una CPU Quad-core ARM A57 a 1.43 GHz y memoria RAM de 4 GB 64-bit LPDDR4.

2.2.2. Redes Neuronales

Las redes neuronales son sistemas informáticos con nodos interconectados que funcionan de manera muy similar a las neuronas del cerebro humano. Usando algoritmos, pueden reconocer patrones ocultos y correlaciones en datos sin procesar, agruparlos y clasificarlos, y con el tiempo aprender y mejorar continuamente. [7]

Figura 3. Origen de las redes neuronales

El objetivo original del enfoque de la red neuronal era crear un sistema computacional que pudiera resolver problemas como un cerebro humano. Sin embargo, con el tiempo, los investigadores cambiaron su enfoque hacia el uso de redes neuronales para hacer coincidir tareas específicas, lo que llevó a desviaciones de un enfoque estrictamente biológico. Desde entonces, las redes neuronales han apoyado diversas tareas, que incluyen visión por computadora, reconocimiento de voz, traducción automática, filtrado de redes sociales, juegos de mesa y videojuegos y diagnóstico médico. A medida que los tamaños de datos

estructurados y no estructurados aumentaron a niveles de big data, las personas desarrollaron sistemas de Deep Learning, que son esencialmente redes neuronales con muchas capas. El Deep Learning permite la captura y extracción de datos cada vez más grandes, incluidos los datos no estructurados. [7]

Las redes neuronales también son ideales para ayudar a las personas a resolver problemas complejos en situaciones de la vida real. Pueden aprender y modelar las relaciones entre entradas y salidas que no son lineales y complejas, hacer generalizaciones e inferencias, revelar relaciones, patrones y predicciones ocultos; y modelar datos altamente volátiles y variaciones necesarias para predecir eventos raros.

Como resultado las redes neuronales pueden mejorar los procesos de decisión en áreas como la medicina en el diagnóstico médico, mediante la visión por computadora interpretando en las imágenes de rayos X las enfermedades padecidas por el paciente.

2.2.2.1. Funcionamiento

Una red neuronal simple incluye una capa de entrada, una capa de salida (o destino) y, en el medio, una capa oculta. Las capas están conectadas a través de nodos y estas conexiones forman una red, la red neuronal de nodos interconectados. [7]

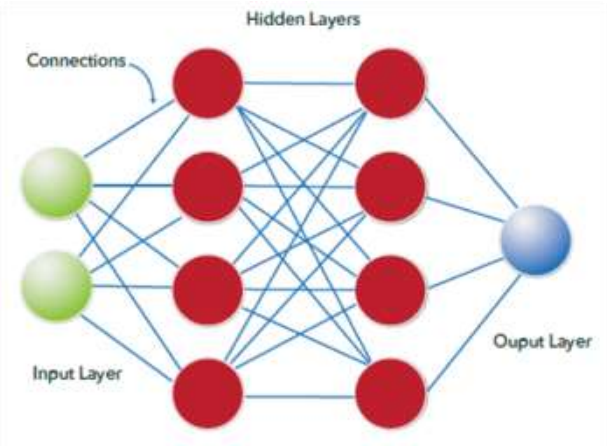

Figura 4. Una red neuronal

Como se muestra en la Figura 4 un nodo sigue el patrón de una neurona en un cerebro humano. De manera similar en comportamiento a las neuronas, los nodos se activan cuando hay suficientes estímulos o entradas. Esta activación se extiende por toda la red, creando una respuesta a los estímulos (salida). Las conexiones entre estas neuronas artificiales actúan como simples sinapsis, lo que permite que las señales se transmitan de una a otra. Señales a través de capas a medida que viajan desde la primera entrada a la última capa de salida, y se procesan en el camino. Cuando se les plantea una solicitud o un problema que resolver, las neuronas ejecutan cálculos matemáticos para averiguar si hay suficiente información para transmitir la información a la siguiente neurona. En pocas palabras, leen todos los datos y descubren dónde existen las relaciones más sólidas. En el tipo de red más simple, las entradas de datos recibidas se suman y, si la suma supera un cierto valor umbral, la neurona dispara y activa las neuronas a las que está conectada. [7]

A medida que aumenta el número de capas ocultas dentro de una red neuronal, se forman redes neuronales profundas (DNN). Las arquitecturas de deep learning llevan las redes neuronales simples al siguiente nivel. Con estas capas, los científicos de datos pueden construir sus propias redes de deep learning que permiten el machine learning, lo que puede entrenar a una computadora para emular con precisión tareas humanas, como reconocer el habla, reconocer imágenes o hacer predicciones. Igualmente, importante, la computadora puede aprender por sí sola reconociendo patrones en muchas capas de procesamiento. Los datos se envían a una red neuronal a través de la capa de entrada, que se comunica con las capas ocultas. El procesamiento se lleva a cabo en las capas ocultas a través de un sistema de conexiones ponderadas. Los nodos en la capa oculta luego combinan los datos de la capa de entrada con un conjunto de coeficientes y asignan pesos apropiados a las entradas. Se resumen estos productos de ponderación de insumos. La suma pasa a través de la función de activación de un nodo, que determina el grado en

que una señal debe avanzar más a través de la red para afectar la salida final. Finalmente, las capas ocultas se vinculan a la capa de salida, donde se recuperan las salidas.

2.2.3. Deep Learning

El Deep Learning es un subconjunto de la inteligencia artificial y el machine learning que utiliza redes neuronales artificiales de varias capas para ofrecer una precisión de última generación en tareas como la detección de objetos, clasificación de imágenes, el reconocimiento de voz, la traducción de idiomas y otras. [8]

Deep Learning, un modelo informático que aprende a realizar tareas de clasificación directamente a partir de imágenes, texto o sonido. Los modelos de Deep Learning pueden obtener una precisión de vanguardia que, en ocasiones, supera el rendimiento humano. Los modelos se entrenan mediante un amplio conjunto de datos etiquetados y arquitecturas de redes neuronales que contienen muchas capas. [9]

2.2.3.1. Requerimientos

El Deep Learning alcanza unos niveles de precisión de reconocimiento de imágenes nunca vistos para ello requiere:

2.2.3.1.1. Potencia de cálculo

El Deep Learning requiere una potencia de cálculo o cómputo significativa. Las GPU de alto rendimiento tienen una arquitectura paralela que resulta eficiente para el Deep Learning. [9]

2.2.3.1.1.1. Unidad de procesamiento gráfico

La unidad de procesamiento gráfico (GPU) es un hardware que es capaz de realizar operaciones matemáticas sobre una gran cantidad de datos al mismo tiempo. No es tan rápida como una unidad de procesamiento central (CPU), pero si se le proporcionan muchos datos para que los procese, lo hace de forma masiva en paralelo y, aunque cada

operación se ejecuta de forma más lenta, el paralelismo de aplicar las operaciones matemáticas a más datos al mismo tiempo supera por mucho el rendimiento de la CPU, lo que permite obtener las respuestas más rápidamente. El big data y la GPU han proporcionado los avances vanguardistas que necesitábamos para utilizar correctamente las redes neuronales. [10]

2.2.3.1.2. Datos etiquetados

El Deep Learning requiere grandes cantidades de datos etiquetados. Cuando se le proporcionen más datos pueden aumentar la precisión.

Se necesita mucho poder computacional para resolver problemas de Deep Learning debido a la naturaleza iterativa de los algoritmos, su complejidad a medida que aumenta el número de capas y los grandes volúmenes de datos necesarios para entrenar las redes neuronales profundas. Mediante estos requerimientos se investigó las necesidades y se optó por el Jetson Nano.

2.2.3.2. Funcionamiento

La mayor parte de los métodos de aprendizaje emplean arquitecturas de redes neuronales, por lo que, a menudo, los modelos de Deep Learning se denominan redes neuronales profundas (DNN). El término profundo suele hacer referencia al número de capas ocultas en la red neuronal. Las redes neuronales tradicionales (ANN) solo contienen dos o tres capas ocultas, mientras que las redes profundas pueden tener hasta ciento cincuenta o mucho más. Los modelos de Deep Learning se entrenan mediante el uso de extensos conjuntos de datos etiquetados y arquitecturas de redes neuronales que aprenden directamente a partir de los datos, sin necesidad de una extracción manual de características. [9]

El Deep Learning cambia la forma en que piensa sobre la representación de los problemas que está resolviendo con el análisis,

pasa de decirle a la computadora cómo resolver un problema a entrenarla para que resuelva el problema por sí misma. [11]

Figura 5. Cómo funciona el Deep Learning

2.2.3.2.1. Representación de características

El Deep Learning es un cambio de paradigma en la construcción de modelos que pasa de la ingeniería de características a la representación de características.

2.2.3.2.2. Capas de aprendizaje profundo

En lugar de utilizar variables conocidas para predecir incógnitas, el aprendizaje profundo utiliza capas de datos para reconocer características latentes de los datos. Más adelante se describirán cada una de las capas.

2.2.3.2.3. Resultados del aprendizaje profundo

La promesa del Deep Learning es que puede conducir a sistemas predictivos que generalicen bien, se adapten bien y mejoren continuamente a medida que llegan nuevos datos.

2.2.3.3. Redes neuronales profundas

Las redes neuronales profundas (DNN) se pueden definir como red neuronal artificial (ANN) con profundidad adicional, es decir, un mayor número de capas ocultas entre las capas de entrada y salida. Los DNN pueden modelar relaciones no lineales complejas. [12]

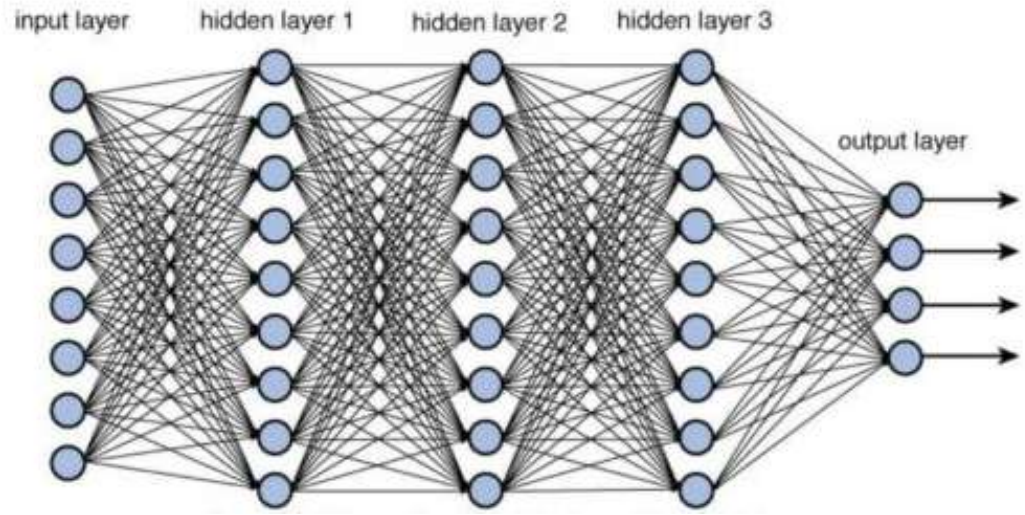

Figura 6. Arquitectura de DNN con múltiples capas

Uno de los tipos más populares de DNN son las conocidas como redes neuronales convolucionales (CNN o ConvNet).

2.2.3.3.1. Redes neuronales convolucionales

Una CNN convoluciona las características aprendidas con los datos de entrada y emplea capas convolucionales 2D, lo cual hace que esta arquitectura resulte adecuada para procesar datos 2D, tales como imágenes. Las CNN contienen cinco tipos de capas: entrada, convolución, agrupación, totalmente conectada y salida. Cada capa tiene un propósito específico, como resumir, conectar o activar. [9]

Las redes neuronales convolucionales han popularizado la clasificación de imágenes y la detección de objetos. Sin embargo, las CNN también se han aplicado a otras áreas, como el procesamiento y la previsión del lenguaje natural. Las CNN eliminan la necesidad de una

extracción de características manual, por lo que no es necesario identificar las características utilizadas para clasificar las imágenes. La CNN funciona mediante la extracción de características directamente de las imágenes. Las características relevantes no se entrenan previamente; se aprenden mientras la red se entrena con una colección de imágenes. Esta extracción de características automatizada hace que los modelos de Deep Learning sean muy precisos para tareas de visión artificial, tales como la clasificación de imágenes.

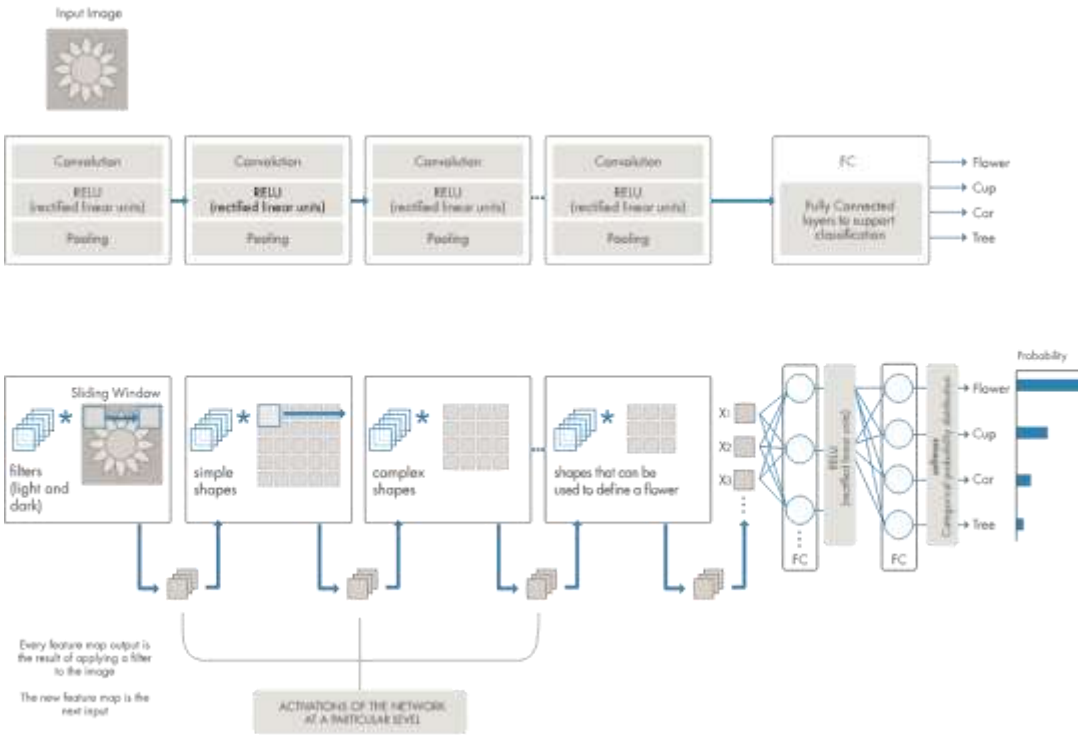

Figura 7. Una red neuronal con muchas capas convolucionales

En la Figura 7 se aplican filtros a cada imagen de entrenamiento con distintas resoluciones, y la salida de cada imagen convolucionada se emplea como entrada para la siguiente capa.

Las CNN aprenden a detectar diferentes características de una imagen mediante decenas o cientos de capas ocultas. Cada capa oculta aumenta la complejidad de las características de la imagen aprendidas. Por

ejemplo, la primera capa oculta podría aprender cómo detectar bordes, mientras la segunda aprende cómo detectar formas más complejas propias de la forma del objeto que se intenta reconocer en las imágenes. [9]

2.2.3.3.1.1. Capas

Estas capas realizan operaciones que alteran los datos con el objetivo de aprender características específicas de dichos datos. Las 3 capas más frecuentes son: convolución, activación o ReLU, y Pooling. [13]

2.2.3.3.1.1.1. Convolución

La convolución somete las imágenes de entrada a un conjunto de filtros convolucionales, cada uno de los cuales activa ciertas características de las imágenes.

2.2.3.3.1.1.2. Unidad lineal rectificada

La unidad lineal rectificada (ReLU) permite un entrenamiento más rápido y eficaz al asignar los valores negativos a cero y mantener los valores positivos. También se lo denomina activación, dado que solo las características activadas pasan a la siguiente capa.

2.2.3.3.1.1.3. Pooling

El Pooling simplifica la salida al disminuir la tasa de muestreo no lineal, reduciendo así el número de parámetros que la red necesita aprender. Estas operaciones se repiten en decenas o cientos de capas, de modo que cada capa aprende a identificar diferentes características.

2.2.3.3.1.2. Valores de peso y sesgo compartidos

Al igual que una red neuronal tradicional, una CNN consta de neuronas con pesos y sesgos. El modelo aprende estos valores durante el proceso de entrenamiento y los actualiza continuamente con cada nuevo ejemplo de entrenamiento. Sin embargo, en el caso de las CNN, los valores de pesos y sesgos son los mismos para todas las neuronas ocultas en una capa concreta. Esto significa que todas las neuronas ocultas detectan la misma característica, como un borde o una mancha, en diferentes regiones

de la imagen. Esto hace que la red tolere la traslación de objetos en una imagen. [13]

2.2.3.3.1.3. Capas de clasificación

Después de aprender las características en varias capas, la arquitectura de una CNN pasa a la clasificación. La penúltima capa está totalmente conectada y proporciona como salida un vector de K dimensiones, donde K es el número de clases que la red será capaz de predecir. Este vector contiene las probabilidades para cada clase de cualquier imagen que se clasifique. La capa final de la arquitectura de CNN utiliza una capa de clasificación, como softmax, para proporcionar la salida de clasificación. [13]

2.2.3.4. Reconocimiento de imágenes

Una aplicación práctica del reconocimiento de imágenes es la impresión automática de subtítulos en imágenes y la descripción de escenas. El Deep learning apoya a la industria del cuidado de la salud al garantizar una mejor atención al paciente y eficiencia operativa. Con el Deep learning, los profesionales de la salud pueden analizar los datos de forma más rápida y precisa. Los registros de salud electrónicos se pueden crear más rápido y con menos errores. Y las redes neuronales, junto con el reconocimiento de imágenes, analizan imágenes médicas en lugar de solo leerlas, lo que ayuda a los profesionales de la salud a identificar enfermedades. [11]

2.2.4. Visión por computadora

La visión por computadora es un campo de la inteligencia artificial que entrena a las computadoras para interpretar y comprender el mundo visual. Usando imágenes digitales de cámaras, videos y modelos de Deep Learning, las máquinas pueden identificar y clasificar objetos con precisión, y luego reaccionar a lo que ven. [14]

2.2.4.1. Funcionamiento

La visión por computadora funciona en tres pasos básicos: [14]

Figura 8. Funcionamiento de la visión por computadora

2.2.4.1.1. Adquirir una imagen

Las imágenes, incluso los conjuntos grandes, se pueden adquirir en tiempo real a través de videos, fotos o tecnología 3D para su análisis.

2.2.4.1.2. Procesando la imagen

Los modelos de Deep Learning automatizan gran parte de este proceso, pero los modelos a menudo se entrenan al ser alimentados primero con miles de imágenes etiquetadas e identificadas previamente.

2.2.4.1.3. Entendiendo la imagen

El paso final es el paso interpretativo, donde se identifica o clasifica un objeto.

Los sistemas de inteligencia artificial pueden ir un paso más allá y tomar medidas basadas en la compresión de la imagen. Hay muchos tipos de visión por computadora, en este proyecto utilizaremos el siguiente:

2.2.4.1.4. Clasificación de imágenes

La clasificación de imágenes agrupa las imágenes en diferentes categorías. [14]

Se conocen soluciones y se tratan de clasificarlas o diagnosticarlas en función a las imágenes radiográficas del tórax procesadas e ingresadas al software.

2.2.4.1.4.1. Apoyo

El software aconseja al usuario a la toma de decisión, que mantiene la capacidad de una última decisión para el diagnóstico médico por parte del profesional de la salud del sanatorio.

2.2.4.1.4.2. Control

El software actúa directamente sin intervención humana.

2.2.4.1.4.3. Aprendizaje

Captación automática de conocimientos durante el entrenamiento.

2.2.5. Procesamiento digital de imágenes

El procesamiento digital de imágenes consiste en el uso de algoritmos computacionales para procesar imágenes digitales. El campo del Procesamiento Digital de Imágenes nace en el momento en que se dispone de capacidad de cálculo, cada vez más importante de los computadores. Una imagen digital se representa en forma matricial y los computadores actuales pueden captar y manipular grandes cantidades de información espacial en forma de matrices de valores. Se sitúa al Procesamiento Digital de Imágenes como una tecnología asociada a las Ciencias de la Computación y, por tanto, cabe pensar como una proyección del término Visión por computadora, dentro del ámbito de la Inteligencia Artificial. [15]

El procesamiento de las imágenes se puede hacer por medio de métodos ópticos, o bien por medio de métodos digitales, en una computadora o edge computing. El procesamiento digital en este proyecto son las imágenes radiográficas del tórax que permite diagnosticar el estado de salud del paciente y cambiar el formato en el que se encuentran las imágenes.

2.2.6. Edge Computing

El edge computing hace referencia al procesamiento de datos de manera local y sin necesidad de comunicación con ningún centro de datos remoto. De esta manera se pueden sacar resultados a partir del análisis de los datos recogidos por los distintos sensores IoT sin tener que enviarlos a través de la red. [16]

2.2.6.1. Edge computing con Jetson Nano

Con el auge de la Inteligencia Artificial y todo lo que ello conlleva, son muchos los fabricantes que han apostado por hacer sistemas y software específico para tareas de Deep Learning. Es el caso de Nvidia y su plataforma de cómputo paralelo llamada CUDA (Compute Unified Device Architecture). Con dicha plataforma, es posible programar software para que corra directamente sobre una GPU aprovechando todo el potencial de estas en cuanto a procesamiento paralelo se refiere. Además, proporciona una capa de abstracción en la complejidad del paralelismo pudiendo desarrollar programas paralelos usando librerías en lenguajes como C/C++, Python o Java. [16]

En un proceso de Deep Learning, típicamente a alto nivel, se distinguen dos fases:

2.2.6.1.1. Entrenamiento

El entrenamiento se nutre a la red neuronal de imágenes catalogadas con su respectiva etiqueta con el fin de que la red aprenda las características de todas las imágenes de una misma etiqueta. [16]

2.2.6.1.2. Inferencia

La inferencia es el proceso por el cual se nutre a una red neuronal de una imagen sin catalogar para que por sí sola determine la clase que más se ajuste. [16]

La inferencia consiste en poner en práctica lo que la IA ha aprendido en el entrenamiento y una vez que la IA aprende crea un modelo de inferencia que se utilizará para resolver o clasificar el problema.

Los procesos de entrenamiento e inferencia requieren de hardware y software especializado para llevar a cabo la tarea ya que son procesos bastante costosos computacionalmente hablando. El proceso de entrenamiento de una red neuronal convolucional desde cero suele realizarse en inmensos centros de datos de manera paralela y haciendo uso de GPUs, estos procesos pueden tardar días e incluso semanas en terminar. Sin embargo, el proceso de inferencia que consiste en clasificar una imagen en una red ya entrenada es relativamente menos costoso y es en este proceso de inferencia donde entra en juego el edge computing. [16]

Conocimientos en el campo de la medicina

2.2.7. Enfermedades respiratorias

Las enfermedades respiratorias son aquellas infecciones que van desde la nariz hasta los pulmones. Los síntomas son el intento del organismo de liberar sustancias tóxicas acumuladas, lo que produce que el cuerpo produzca ciertas crisis curativas para expulsar esta enfermedad del cuerpo. Las causas infecciosas se relacionan a microorganismos como: virus, bacterias y hongos que se encuentran en el ambiente o bien por alergias. En su mayoría son de corta duración y se controlan fácilmente, cuando se atienden oportunamente y sólo en algunos casos llegan a ser muy graves [17].

La Organización Mundial de la Salud (OMS) revela [18] las principales causas de muerte en todo el mundo, en 2019, la neumonía y otras infecciones de las vías respiratorias inferiores fueron el grupo más mortífero de enfermedades transmisibles y en conjunto se clasificaron como la cuarta causa principal de muerte. Ahora bien, en comparación con el año 2000, esas infecciones se cobran menos vidas que en el pasado, ya que el número mundial de muertes por esa causa ha disminuido en casi

medio millón, lo que refleja el éxito de las iniciativas para prevenir la infección, detectar el virus mediante pruebas y tratar la enfermedad en las dos últimas décadas. La tuberculosis ya no figura entre las 10 principales causas mundiales, al pasar del séptimo lugar en 2000 al decimotercero en 2019, con una reducción del 30% en las muertes mundiales. Con todo, sigue siendo una de las 10 causas principales de muerte en las regiones de África y Asia Sudoriental, donde es la octava y quinta causa principal, respectivamente.

La disponibilidad de servicios para prevenir, diagnosticar y tratar enfermedades es clave para reducir el número de muertes y la discapacidad, e influye en la clasificación de las diferentes afecciones. Estas nuevas estimaciones indican claramente dónde se necesitan con más urgencia inversiones adicionales en servicios.

En el año 2022 con fuente consultada en fecha 2 de agosto a nivel mundial el covid-19 se ha cobrado trágicamente más de 6.398.412 de vidas y ha habido 575.887.049 casos confirmados, notificados a la OMS [19]. Las personas que viven con afecciones de salud preexistentes (como cardiopatías, diabetes y afecciones respiratorias) corren un mayor riesgo de tener complicaciones y morir debido a la covid-19. La situación actual del covid-19 en nuestro país en la misma fecha de consulta con datos reportados por la OMS con 707.109 casos confirmados y 19 220 muertes confirmadas [20].

En este proyecto estaré diagnosticando las siguientes enfermedades respiratorias: covid-19, la neumonía por bacterias, neumonía por virus y la tuberculosis.

2.2.7.1. Neumonía

La neumonía es una infección en uno o ambos pulmones. Causa que los alvéolos pulmonares se llenen de líquido o pus. Puede variar de leve a grave, según el tipo de germen que causa la infección, su edad y su estado general de salud. [21]

Las infecciones bacterianas y virales pueden causar neumonía.

Figura 9. Radiografías de tórax en pacientes con neumonía y normal

La radiografía de tórax normal (panel izquierdo) muestra pulmones claros sin áreas de opacificación anormal en la imagen. La neumonía bacteriana (centro) presenta típicamente una consolidación lobar focal, en este caso en el lóbulo superior derecho (flechas blancas), mientras que la neumonía viral (derecha) se manifiesta con un patrón "intersticial" más difuso en ambos pulmones. [22]

2.2.7.1.1. Neumonía Bacteriana

Las bacterias son la causa más común. La neumonía bacteriana puede ocurrir por sí sola. También puede desarrollarse después de haber tenido ciertas infecciones virales, como resfriados o gripe. Puede afectar una parte del pulmón (lóbulo), una afección llamada neumonía lobular. [22]

Varios tipos diferentes de bacterias pueden causar neumonía, incluyendo: Streptococcus pneumoniae, Legionella pneumophila, Mycoplasma pneumoniae, Chlamydophila pneumoniae, Klebsiella, Nocardia, Escherichia, entre otros.

2.2.7.1.2. Neumonía Viral

Los virus que infectan las vías respiratorias pueden causar neumonía. A menudo, la neumonía viral es leve y desaparece por sí sola en pocas semanas, en ocasiones es lo suficientemente grave como para necesitar tratamiento en un hospital. Si tiene neumonía viral, corre el riesgo de contraer también neumonía bacteriana. Los diferentes virus que pueden

causar neumonía incluyen: Virus respiratorio sincitial, algunos virus del resfriado común y la gripe, SARS-CoV-2 el virus que causa COVID-19. [22]

Algunos de los virus que causan resfriados y gripe pueden causar neumonía. Los virus son la causa más común de neumonía en niños menores de 5 años. La neumonía viral suele ser leve. Pero en algunos casos puede llegar a ser muy grave. El covid-19 puede causar neumonía, que puede llegar a ser grave. [23]

2.2.7.1.3. Covid-19

La enfermedad por coronavirus (covid-19) es una enfermedad infecciosa causada por el virus SARS-CoV-2, una cepa del coronavirus. Los primeros casos se observaron en Wuhan, China, a fines de diciembre de 2019 antes de propagarse a nivel mundial. El brote actual fue reconocido oficialmente como una pandemia por la Organización Mundial de la Salud (OMS) el 11 de marzo de 2020. La mayoría de las personas infectadas con el virus experimentaron una enfermedad respiratoria de leve a moderada y se recuperaron sin requerir un tratamiento especial. Sin embargo, algunos se enfermaron gravemente y requerirán atención médica. Las personas mayores y aquellas con afecciones médicas subyacentes, como enfermedades cardiovasculares, diabetes, enfermedades respiratorias crónicas o cáncer, tienen más probabilidades de desarrollar enfermedades graves. Cualquiera puede enfermarse de covid-19 y enfermarse gravemente o morir a cualquier edad. [24].

2.2.7.1.4. Tuberculosis

La tuberculosis pulmonar (TB) es una infección bacteriana contagiosa que compromete los pulmones y que puede propagarse a otros órganos. Esta enfermedad es causada por la bacteria Mycobacterium tuberculosis, las bacterias pueden propagarse fácilmente de una persona infectada a otra no infectada. Se puede adquirir por la inhalación de gotitas de agua provenientes de la tos o el estornudo de una persona infectada. La mayoría de las personas se recupera de la infección de TB primaria sin

manifestación mayor de la enfermedad. La infección puede permanecer inactiva (latente) por años. En algunas personas, se activa de nuevo (reactivación). [25].

Estos serían algunos los tipos de bacterias y virus que ocasionan las enfermedades respiratorias de las cuales estamos diagnosticando.

Tipos	Enfermedades respiratorias
Virus	SARS-CoV-2
	SARS-CoV-1
	MERS-COV
	Varicela
	Influenza
	Herpes
Bacterias	Streptococcus
	Klebsiella
	Escherichia
	Nocardia
	Mycoplasma
	Legionella
	Chlamydophila
	Mycobacterium

Tabla 1. Tipos de enfermedades virus y bacterias

Como se muestra en la tabla 1 para el diagnóstico médico de estas enfermedades respiratorias se separó el virus del covid-19 (SARS-CoV-2) con relación a los demás, respectivamente los mismo con la bacteria de la tuberculosis (Mycobacterium) con los demás baterías.

2.2.7.2. Diagnóstico médico

El diagnóstico por imágenes permite a los profesionales de la salud observar el interior del cuerpo para buscar indicios de una afección médica.

Una variedad de aparatos y técnicas pueden crear imágenes de las estructuras y procesos dentro de su cuerpo. El tipo de imagen que use el médico dependerá de sus síntomas y de la parte del cuerpo que debe examinarse. [26]

La neumonía en ocasiones puede ser difícil de diagnosticar porque puede causar algunos de los mismos síntomas que un resfriado o gripe. Puede llevarle tiempo darse cuenta de que tiene una afección más grave [21]. Para hacer un diagnóstico, el profesional de la salud puede utilizar:

- Su historia clínica, incluyendo preguntas sobre sus síntomas.
- Un examen físico, que incluye escuchar sus pulmones con un estetoscopio.
- Varias pruebas, incluyendo:
  - Radiografía de tórax.
  - Exámenes de sangre como un conteo sanguíneo completo para ver si su sistema inmunitario está combatiendo activamente una infección.
  - Un hemocultivo para determinar si tiene una infección bacteriana que se ha diseminado al torrente sanguíneo.

En este proyecto estaré utilizando las pruebas de imágenes de radiografía del tórax como objeto de estudio para la elaboración del diagnóstico médico .

2.2.7.2.1. Radiografía del tórax

Los rayos X, o radiografía del tórax utilizan una dosis muy pequeña de radiación ionizante para producir imágenes del interior del tórax. Se utiliza para evaluar los pulmones, el corazón, la pared del pecho, las vías respiratorias y los huesos de la columna y el tórax, y se puede utilizar para diagnosticar la falta de aliento, una tos persistente, fiebre, dolor de pecho o lesiones. También se puede utilizar para ayudar a diagnosticar y monitorear el tratamiento de una variedad de condiciones de los pulmones tales como

la neumonía, covid-19, el enfisema y el cáncer. Debido a que los rayos X del tórax son rápidos y fáciles, resultan particularmente útiles para diagnósticos y tratamientos de emergencia. [27]

La radiografía del tórax es el examen de diagnóstico más comúnmente realizado que ayuda a los médicos a diagnosticar y tratar las condiciones médicas. Los rayos X son la forma más antigua y la que se usa con más frecuencia para producir imágenes médicas.

2.2.7.3. Razones

El médico ordena una radiografía torácica si tiene cualquiera de los siguientes síntomas: Tos persistente, dolor torácico por una lesión en el tórax (con posible fractura de costillas o complicación pulmonar) o a causa de problemas cardíacos, tos con sangre, dificultad para respirar, fiebre, entre otras. También se puede hacer si tiene signos de tuberculosis, cáncer pulmonar o cualquier otra enfermedad pulmonar o torácica. [28]

CAPÍTULO III

3. MARCO METODOLÓGICO

3.1. TIPO DE INVESTIGACIÓN

El tipo de investigación a ser utilizado en este proyecto es la investigación tecnológica, para la interpretación de todos los datos recabados en el proceso de relevamiento de la información en el sanatorio involucrado, pues según Espinoza [29], en su libro de Metodología de la investigación pensado en sistemas manifiesta que “La investigación tecnológica tiene como propósito aplicar el conocimiento científico para solucionar los diferentes problemas que beneficien a la sociedad”.

3.2. NIVEL DE INVESTIGACIÓN

El nivel de investigación utilizado en este proyecto es la investigación aplicada, según Espinoza [29], en su libro describe que “La investigación aplicada tiene como propósito aplicar los resultados de la investigación para diseñar tecnologías de aplicación inmediata en la solución de los problemas de la sociedad.”

3.3. TÉCNICAS E INSTRUMENTOS DE RECOLECCIÓN DE DATOS

Para el desarrollo de este proyecto de investigación se utilizaron una serie de técnicas para la recolección de datos, que permitieron obtener un panorama claro de la situación real del sanatorio y por ende la formulación del objetivo de la investigación. Los instrumentos de recolección de datos se han utilizado entrevistas semiestructuradas con preguntas abiertas y cerradas a los profesionales médicos que trabajan en el Sanatorio San José en la ciudad de Coronel Oviedo.

Entre las técnicas utilizadas para el relevamiento de la información se consultó la fuente en la plataforma científica kaggle para extraer base de datos de imágenes radiográficas del tórax de enfermedades respiratorias que sirvieron para realizar el entrenamiento del modelo de Deep Learning para utilizar en el proyecto.

3.3.1. Kaggle

Kaggle es una subsidiaria de Google LLC, es una comunidad Data Science y profesionales del aprendizaje automático más grande del mundo. Kaggle permite a los usuarios encontrar y publicar conjuntos de datos, explorar y crear modelos en un entorno de ciencia de datos. Ahora ofrece una plataforma de datos públicos, un banco de trabajo basado en la nube para ciencia de datos y educación en inteligencia artificial. [30]

3.3.1.1. Base de datos

Las base de datos de imágenes utilizadas para este proyecto fueron:

3.3.1.1.1. Base de datos de radiografías de Covid-19

Base de datos de radiografía de covid-19 (Ganador del premio de conjunto de datos de covid-19 de Kaggle Community). [31] .

Figura 10. Base de datos de radiografía de covid-19

Un equipo de investigadores de la Universidad de Qatar, Doha, Qatar, y la Universidad de Dhaka, Bangladesh, junto con sus colaboradores de Pakistán y Malasia, en colaboración con médicos, han creado una base de datos de imágenes de rayos X de tórax para casos positivos de COVID-19 junto con Imágenes de Neumonía bacteriana y Viral.

La base de datos de imágenes contiene:

1ra. Base de datos de Radiografías del Tórax			
CLASES	**IMÁGENES**	**FORMATO**	**DIMENSIÓN**
Casos positivos de covid-19	3.616	PNG	299 X 299 px
Neumonías bacterianas	6.012	PNG	299 X 299 px
Neumonías virales	1.345	PNG	299 X 299 px
Casos Normales	10.200	PNG	299 X 299 px
TOTAL	**21.173**		

Tabla 2. Estructura de la 1ra base de datos radiografías del tórax

3.3.1.1.2. Base de datos de rayos X del tórax Tuberculosis

La base de datos de rayos X del tórax más grande de Tuberculosis. [32]

Figura 11. Base de datos de rayos X de Tuberculosis

Un equipo de investigadores de la Universidad de Qatar, Doha, Qatar, y la Universidad de Dhaka, Bangladesh, junto con sus colaboradores de Malasia, en colaboración con médicos de Hamad Medical Corporation y Bangladesh, han creado una base de datos de imágenes de rayos X de tórax para casos positivos tuberculosis (TB) junto con imágenes normales.

El conjunto de datos contiene:

2da. Base de datos de Radiografías del Tórax			
CLASES	**IMÁGENES**	**FORMATO**	**DIMENSIÓN**
Casos positivos tuberculosis	700	PNG	299 X 299 px
Casos Normales	3.500	PNG	299 X 299 px
TOTAL	**4.200**		

Tabla 3. Estructura de la 2da base de datos radiografías del tórax

No utilice las imágenes de casos normales.

3.4. DESCRIPCIÓN DE LOS PROCEDIMIENTOS DE ANÁLISIS DE DATOS

3.4.1. Preparación del conjunto de datos

Se proporciona un conjunto de datos de 21.611 imágenes radiográficas del tórax en los cuales está organizado en tres directorios que son de entrenamiento (train), validación (val) y prueba (test), y cada una contiene subcarpetas para cada clase de enfermedades respiratorias. Se seleccionaron las imágenes radiológicas de tórax (posterior y anterior) de pacientes pediátricos y adultos. Las radiografías se revisaron inicialmente para el control de calidad mediante la eliminación de todos los escaneos de baja calidad o ilegibles, garantizando su limpieza y correcto etiquetado, para el entrenamiento del modelo de inteligencia artificial basado en deep learning.

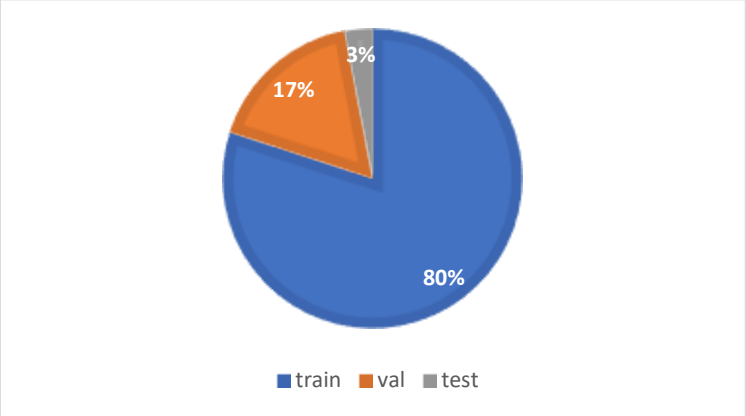

Figura 12. Gráfica de partición del conjunto de datos

- El conjunto de datos de entrenamiento de las imágenes se usan para el aprendizaje por transferencia.

- El conjunto de datos de validación de las imágenes se usan para evaluar la precisión de la clasificación durante el entrenamiento.

- El conjunto de datos de prueba de las imágenes usaremos después de que se complete el entrenamiento.

Preparación del conjunto de datos			
CLASES	**Porcentaje de partición de imágenes**		
	80 %	**17 %**	**3 %**
Covid-19	2.893	615	108
Neumonía bacteriana	4.810	1.022	180
Neumonía viral	1.076	229	40
Normal	8.160	1.734	306
Tuberculosis	560	119	21
TOTAL	**17.499**	**3.719**	**655**

Tabla 4. Preparación del conjunto de datos

Creamos un archivo de texto que definirá las etiquetas de cada clase para el entrenamiento del modelo.

3.4.2. Aprendizaje por Transferencia

El aprendizaje por transferencia es una técnica para volver a entrenar un modelo de Deep Learning en un nuevo conjunto de datos lo que lleva menos tiempo que entrenar una red desde cero. Con el aprendizaje por transferencia, los pesos de un modelo previamente entrenado se ajustan para clasificar en un conjunto de datos ya preparado.

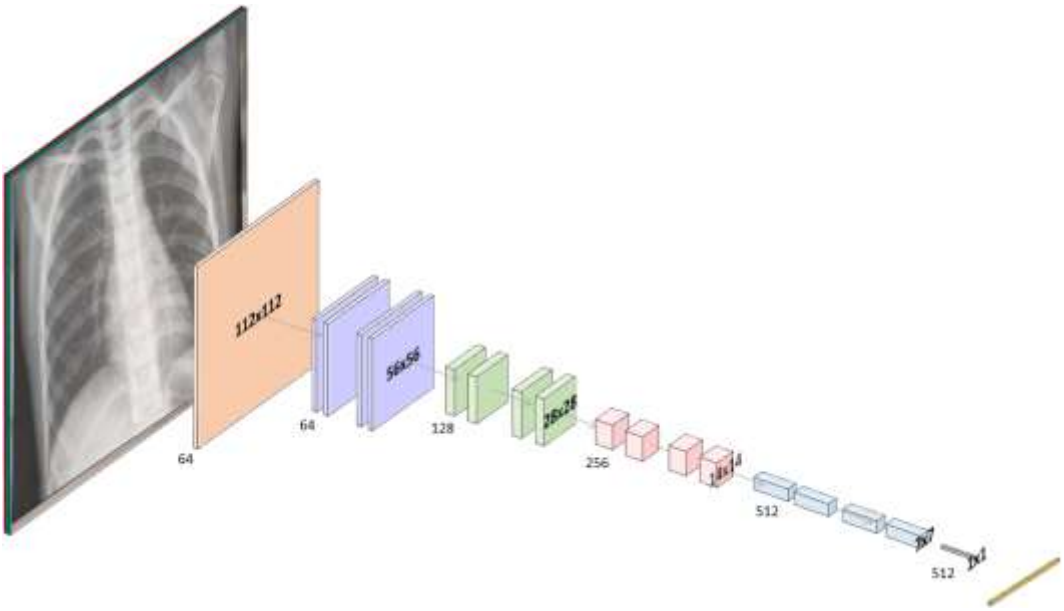

Figura 13. Aprendizaje por transferencia

Aunque el entrenamiento generalmente se realiza en una PC, servidor o instancia en la nube con GPU discretas debido a los grandes conjuntos de datos que se usan y las demandas de poder computacional asociada, al usar el aprendizaje por transferencia podemos volver a entrenar varias redes neuronales profundas a bordo con el Jetson Nano.

Los framework de Deep Learning ampliamente utilizados como, PyTorch, TensorFlow, MXNet y otros se basan en bibliotecas aceleradas por GPU, como cuDNN, NCCL y DALI para ofrecer un entrenamiento acelerado por varias GPU de alto rendimiento. El framework utilizado en este proyecto es el PyTorch que acelera los modelos con una integración Torch-TensorRT con una línea de código. Obtiene una inferencia 6 veces más rápida con TensorRT.

3.4.3. Entrenamiento del modelo

Para el entrenamiento del modelo de IA basado en Deep Learning lo ejecutamos con el lenguaje de programación python en la terminal del sistema operativo, con argparse el analizador de opciones de línea de comandos le pasamos los argumentos necesarios como el modelo preentrenado, workers y batch-size, época, la ubicación de nuestro directorio de conjunto de datos de imágenes que hemos preparado anteriormente y la ubicación donde se guardará el modelo.

La línea de comando utilizada en la terminal del sistema.

```
$ python3 train.py --arch=resnet18 --batch-size=8 --
workers=2 --epochs=100 --model-dir=models/CRX-Torax data/CRX-
Torax
```

Figura 14. Entrenamiento del modelo en la terminal.

3.4.3.1. Métricas de entrenamiento

La salida de estadísticas muestra el proceso de entrenamiento en la terminal, explicaremos las informaciones que se observan en la Figura 15.

3.4.3.1.1. Épocas

Una época (Epoch en inglés) es un pase de entrenamiento completo sobre el conjunto de datos. El valor asignado es de 100 épocas. Epoch:[N] significa que actualmente se encuentra en la época 0 …100.

Las imágenes de entrenamiento se procesan en mini lotes para mejorar el rendimiento. El tamaño de lote (batch-size) es de 8 imágenes .

3.4.3.1.2. Time

Tiempo de procesamiento del lote de imágenes actual (en segundos).

3.4.3.1.3. Data

Tiempo de carga del disco del lote de imágenes actual (en segundos).

3.4.3.1.4. Loss

Los errores acumulados que cometió el modelo (esperados frente a predichos).

3.4.3.1.5. Acc@1

La precisión de clasificación Top-1 sobre el lote.

3.4.3.1.5.1. Top-1

Top-1 significa que el modelo predijo exactamente la clase correcta.

3.4.3.2. Entrenamientos de modelos realizados

MODELOS ENTRENADOS				
MODELO	**TAMAÑO**	**DATASET CLASES**	**ÉPOCAS**	**ACCURACY**
ResNet18	44,8 MB	Covid-19, Neumonía, Normal, Tuberculosis	35	84,21 %
ResNet50	94,3 MB	Covid-19, Neumonía, Normal, Tuberculosis	35	84,21 %
ResNet50	94,3 MB	Covid-19, Neumonía, Normal, Tuberculosis	70	86,84 %
GoogleNet	45,1 MB	Covid-19, Neumonía, Normal, Tuberculosis	35	89,47 %
ResNet18	44,8 MB	Covid-19, Neumonía Bacteriana, Neumonía Viral, Normal	35	90, 16 %
ResNet18	44,8 MB	Covid-19, Neumonía Bacteriana, Neumonía Viral, Normal	70	93, 07 %
ResNet18	44,8 MB	Covid-19, Neumonía Bacteriana, Neumonía Viral, Normal	100	93, 80 %
ResNet18	44,8 MB	Covid-19, Neumonía Bacteriana, Neumonía Viral, Normal, Tuberculosis	35	90, 90 %
ResNet18	44,8 MB	Covid-19, Neumonía Bacteriana, Neumonía Viral, Normal, Tuberculosis	70	93, 17 %
ResNet50	94,3 MB	Covid-19, Neumonía Bacteriana, Neumonía Viral, Normal, Tuberculosis	80	93, 92 %
ResNet18	44,8 MB	Covid-19, Neumonía Bacteriana, Neumonía Viral, Normal, Tuberculosis	100	**94,5 %**

Tabla 5. Entrenamientos de modelos realizados

3.4.4. Precisión del modelo en el entrenamiento

El conjunto de datos de imágenes radiográficas del tórax, el entrenamiento en el modelo preentrenado ResNet-18 tomó aproximadamente cuarenta horas (40 hs) para entrenar el modelo de Deep Learning a 100 épocas y se obtuvo una precisión de clasificación del 94,5%.

A continuación se muestra un gráfico para analizar la progresión del entrenamiento de las épocas frente a la precisión del modelo de aprendizaje:

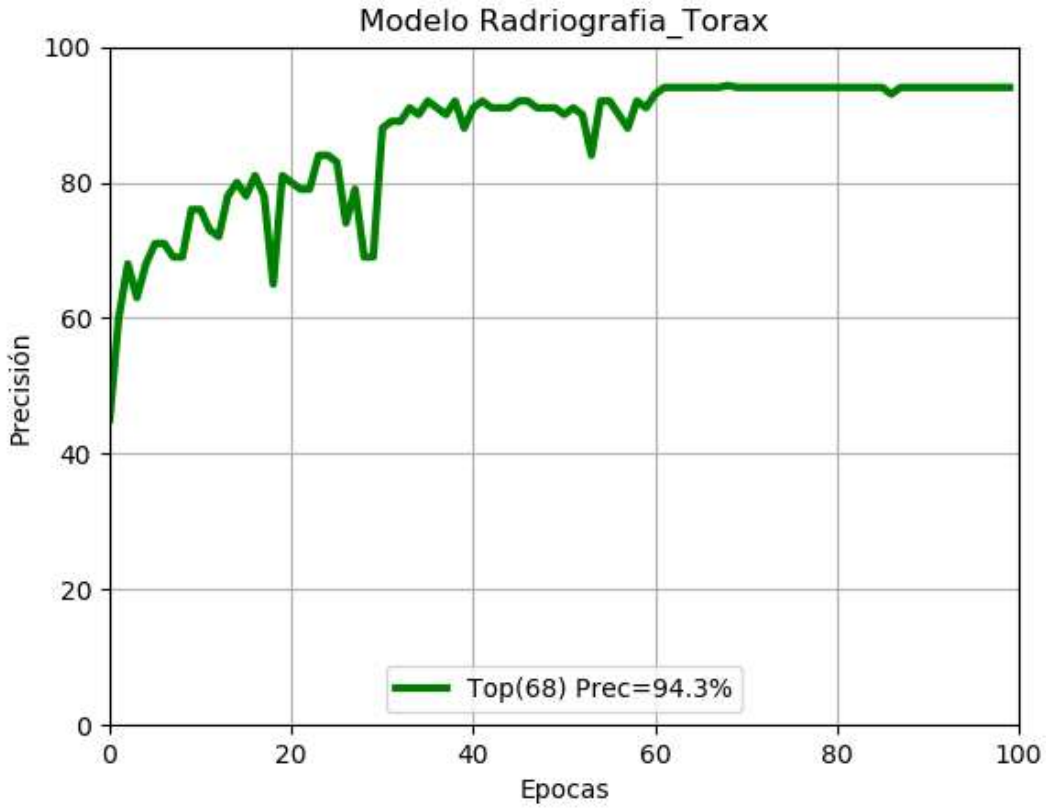

Figura 15. Gráfica de entrenamiento del modelo de Deep Learning

3.4.4.1. Conversión del modelo a ONNX

Al terminar el entrenamiento obtenemos el modelo de Deep Learning a utilizar en el proyecto.

Figura 16. Modelo de Deep Learning

Para ejecutar nuestro modelo de Deep Learning con TensorRT para realizar pruebas e inferencias, primero debo convertir el modelo que está en formato PyTorch al formato ONNX para que TensorRT pueda cargarlo.

Figura 17. Proceso de conversión del modelo de Deep Learning

La línea de comando utilizada para convertir el modelo de Deep Learning.

```
$. python3 onnx_export.py --model-dir=models/CRX-Torax/
```

Figura 18. Modelo de Deep Learning a formato ONNX

3.5. POBLACIÓN Y MUESTRA

Todos los intervenidos son referentes a los pacientes que se acercaron a diagnosticarse por enfermedades respiratorias en el sanatorio San José de Coronel Oviedo, se consideraron en este proyecto una cantidad de 105 muestras de imágenes radiográficas del tórax de diferentes pacientes, algunos de ellos con imágenes frontales, perfil, acostado y sentado en un periodo de 8 días en las que atiende un médico.

3.5.1. Criterios de inclusión

Se tomaron en cuenta todos aquellos pacientes que poseían diagnóstico con cuadro de covid-19, neumonía bacteriana, viral, tuberculosis y pacientes normales.

3.5.2. Criterios de exclusión

Se excluyeron todos aquellos pacientes que no tenían un diagnóstico con cuadros respiratorios.

3.6. CONSIDERACIONES ÉTICAS

Todos los datos de los pacientes y médicos que aparecen en las imágenes radiográficas del tórax serán de uso exclusivamente académicos para la demostración del modelo de aprendizaje y estarán bajo resguardo confidencial.

CAPÍTULO IV

4. MARCO ANALÍTICO

4.1. PRESENTACIÓN Y ESTUDIO DE LOS RESULTADOS

4.1.1. Procesamiento de imágenes con TensorRT

Para el procesamiento de las imágenes con TensorRT usaremos los parámetros de línea de comandos extendidos en la terminal para ejecutar nuestro programa de diagnóstico en Python, para la clasificación de las enfermedades respiratorias. Ingresando la ubicación de las imágenes radiográficas del tórax del paciente y la ubicación donde se guardará el diagnóstico médico, una vez completado lo ejecutamos.

```
$ ./diagnostico.py radiografias/PACIENTE_18.jpg
diagnosticos/Diagnostico_Paciente_18.jpg
```

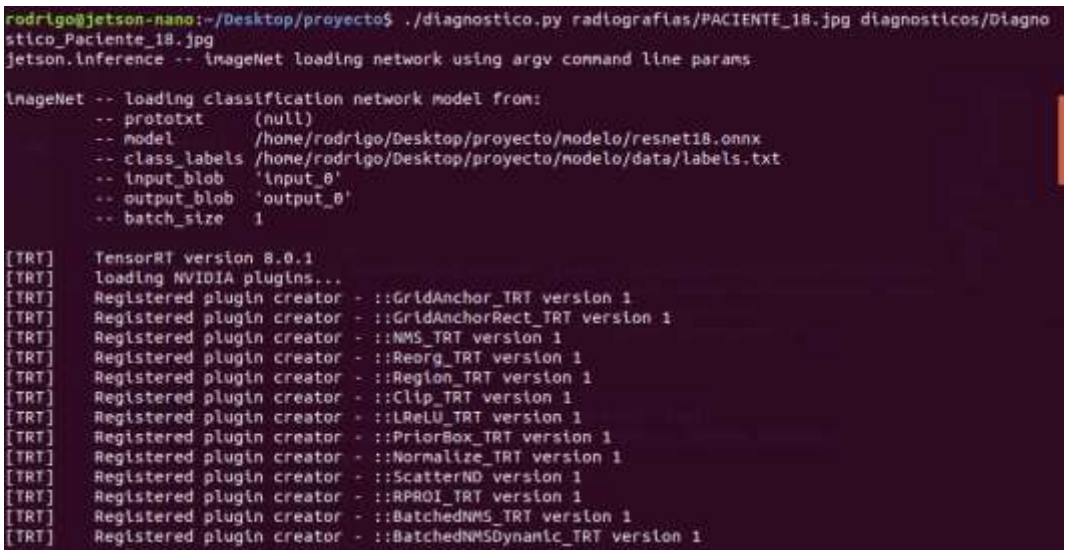

Figura 19. Línea de comandos para el diagnóstico médico 1

```
  -- URI: display://0
     - protocol:  display
     - location:  0
  -- deviceType: display
  -- ioType:     output
  -- codec:      raw
  -- width:      1024
  -- height:     600
  -- frameRate:  0.000000
  -- bitRate:    0
  -- numBuffers: 4
  -- zeroCopy:   true
  -- flipMethod: none
  -- loop:       0
  -- rtspLatency 2000
------------------------------------------------
[image]  loaded 'radiografias/PACIENTE_18.jpg'  (1024x1042, 3 channels)
class 0000 - 0.996930  (COVID-19
[OpenGL] glDisplay -- set the window size to 1024x600
[OpenGL] creating 1024x1042 texture (GL_RGB8 format, 3201024 bytes)
[cuda]   registered openGL texture for interop access (1024x1042, GL_RGB8, 3201024 bytes)
[image]  saved 'diagnosticos/Diagnostico_Paciente_18.jpg'  (1024x1042, 3 channels)

[TRT]    ------------------------------------------------
[TRT]    Timing Report /home/rodrigo/Desktop/proyecto/modelo/resnet18.onnx
[TRT]    ------------------------------------------------
[TRT]    Pre-Process   CPU   0.07750ms  CUDA   0.62489ms
[TRT]    Network       CPU  19.35511ms  CUDA  18.66641ms
[TRT]    Post-Process  CPU   0.06138ms  CUDA   0.06000ms
[TRT]    Total         CPU  19.49391ms  CUDA  19.35130ms
[TRT]    ------------------------------------------------
```

Figura 20. Diagnóstico médico por línea de comandos 1

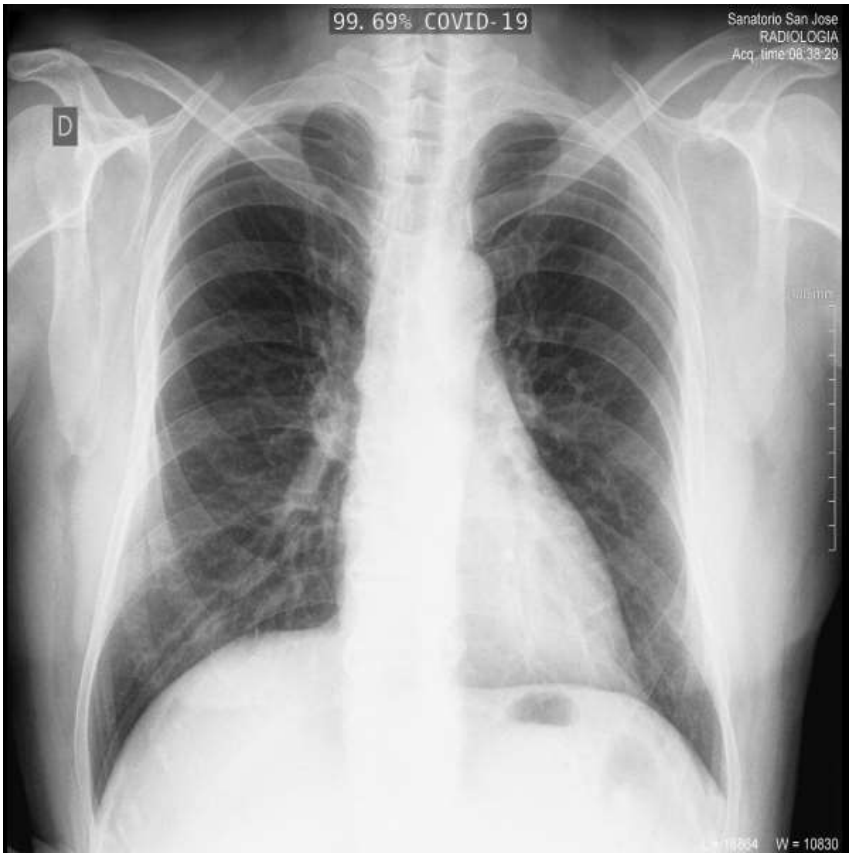

Figura 21. Diagnóstico médico con un 99.69% de Covid-19

```
$ ./diagnostico.py radiografias/PACIENTE_14.JPEG
diagnosticos/Diagnostico_Paciente_14.png
```

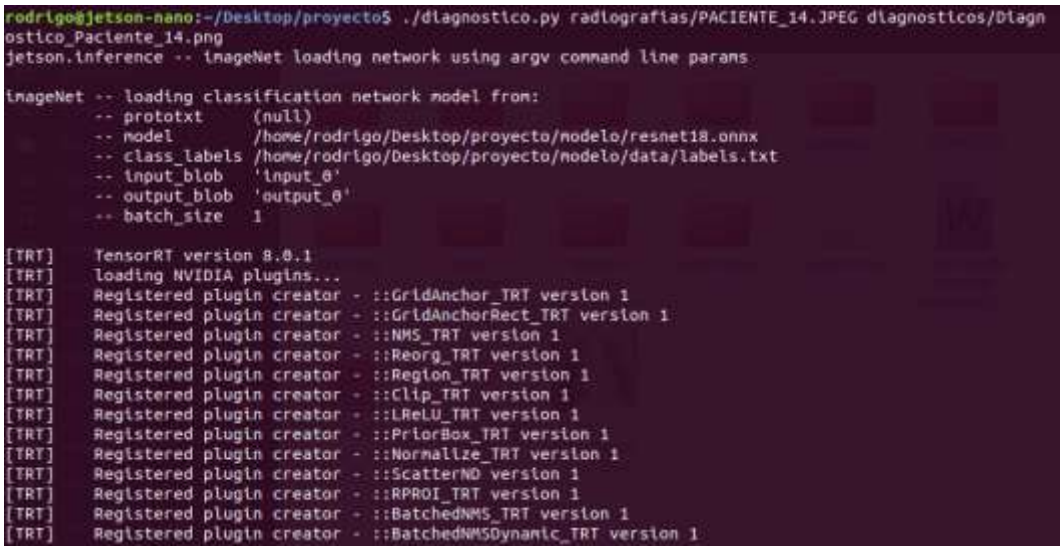

Figura 22. Línea de comandos para el diagnóstico médico 2

Se ejecuta una línea de comandos donde el resultado del diagnóstico médico se guarda en otro formato de imagen.

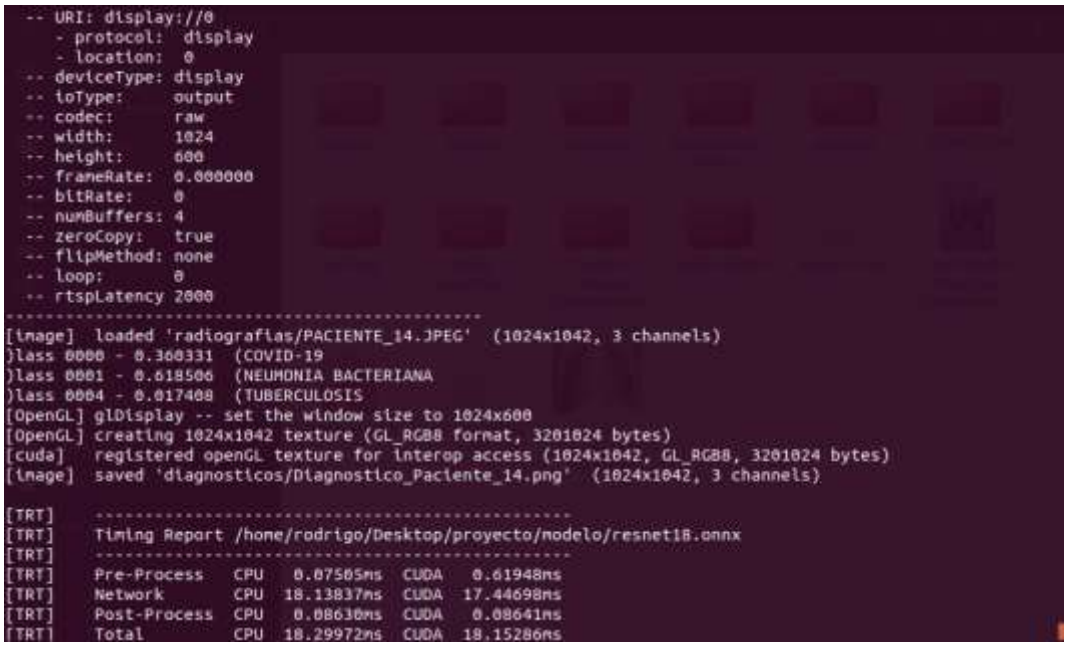

Figura 23. Diagnóstico médico por línea de comandos 2

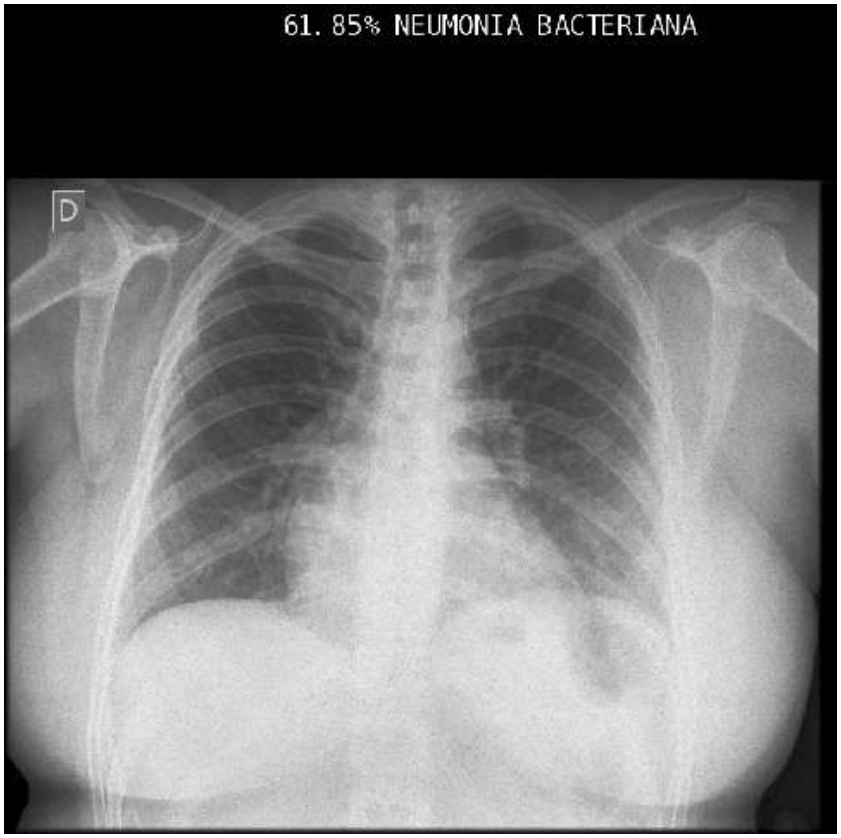

Figura 24. Diagnóstico médico con un 61.85% de N. Bacteriana

4.1.2. Resultados de test del conjunto de datos

Estudio de los resultados del test del conjunto de datos, realizando procesamiento de imágenes con TensorRT.

4.1.2.1. Diagnósticos Covid-19

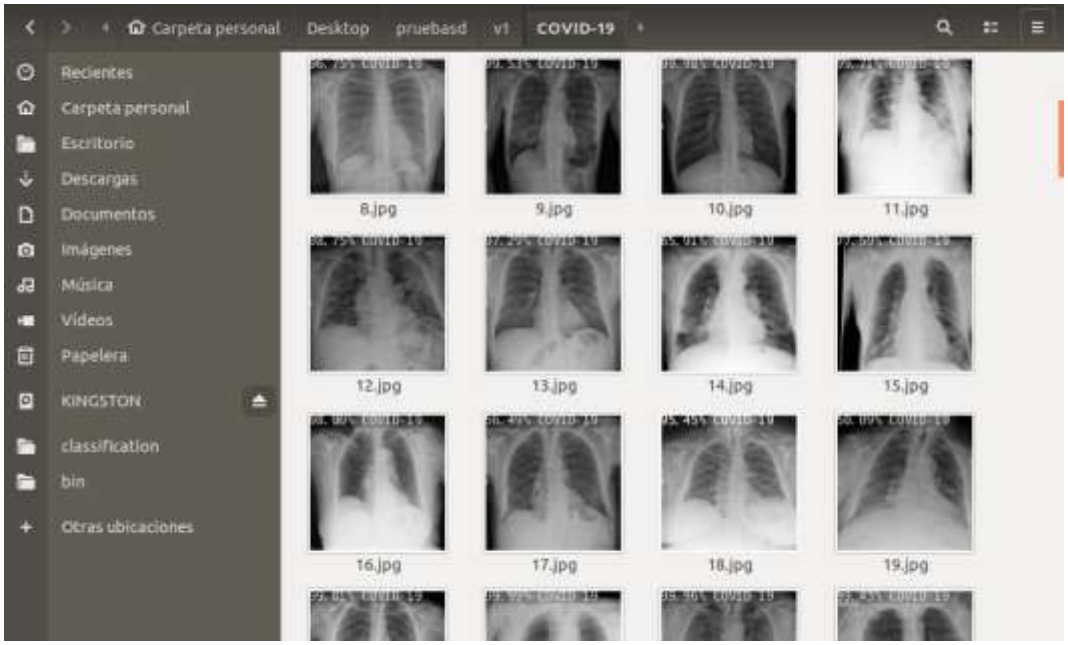

Figura 25. Resultados de diagnóstico del test de covid-19

Un total de 108 imágenes radiográficas del tórax del test de covid-19 fueron clasificados y diagnosticados con los siguientes resultados:

Test de Covid-19					
Clases	Covid-19	Bacteriana	Viral	Normal	Tuberculosis
Diagnóstico	106	1	0	1	0

Tabla 6. Diagnósticos de Test de Covid-19

Los resultados del diagnóstico médico de las imágenes radiográficas de test covid-19 del conjunto de datos se puede observar en la Tabla 6.

4.1.2.2. Diagnósticos neumonía bacteriana

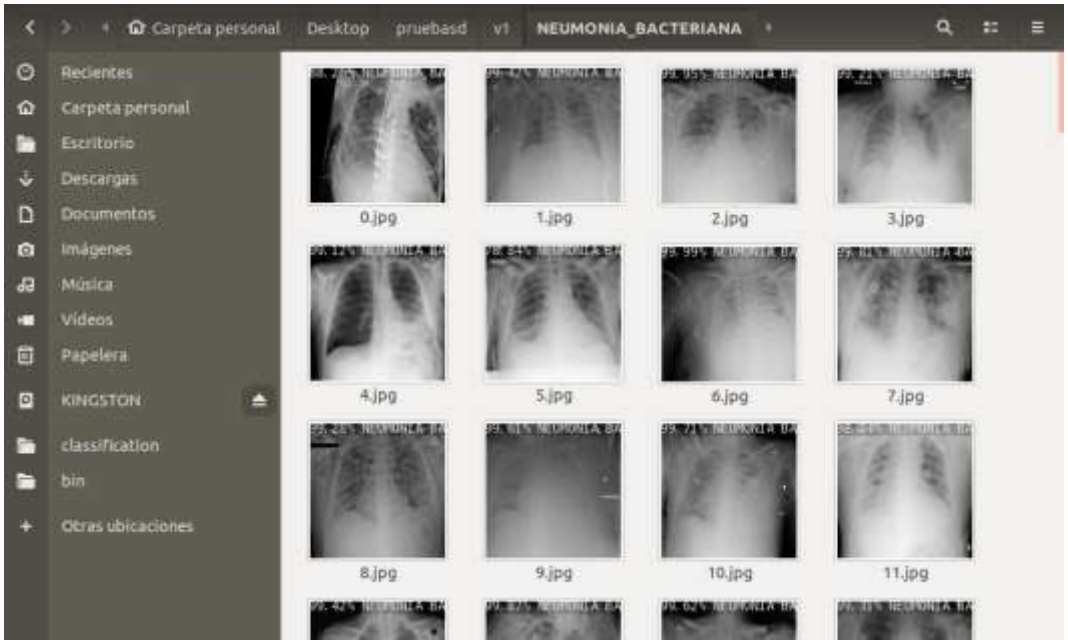

Figura 26. Resultados de diagnóstico del test de neumonía bacteriana

Un total de 180 imágenes radiográficas del tórax del test de neumonía bacteriana fueron clasificados y diagnosticados con los siguientes resultados:

Test de Neumonía Bacteriana					
Clases	Covid-19	Bacteriana	Viral	Normal	Tuberculosis
Diagnóstico	2	175	0	3	0

Tabla 7. Diagnósticos de Test de Neumonía Bacteriana

Los resultados del diagnóstico médico de las imágenes radiográficas de test neumonía bacteriana del conjunto de datos se puede observar en la Tabla 7.

4.1.2.3. Diagnósticos neumonía viral

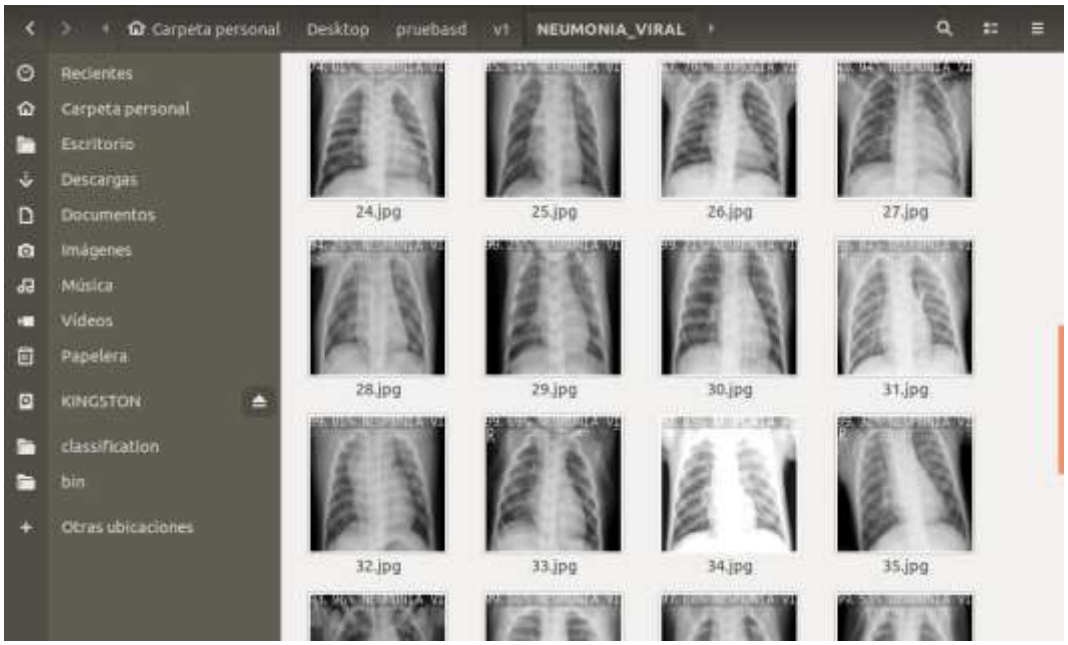

Figura 27. Resultados de diagnóstico del test de neumonía viral

Un total de 40 imágenes radiográficas del tórax del test de neumonía viral fueron clasificados y diagnosticados con los siguientes resultados:

Test de Neumonía Viral					
Clases	Covid-19	Bacteriana	Viral	Normal	Tuberculosis
Diagnóstico	1	0	39	0	0

Tabla 8. Diagnósticos de Test de Neumonía Viral

Los resultados del diagnóstico médico de las imágenes radiográficas de test neumonía viral del conjunto de datos se puede observar en la Tabla 8.

4.1.2.4. Diagnósticos tuberculosis

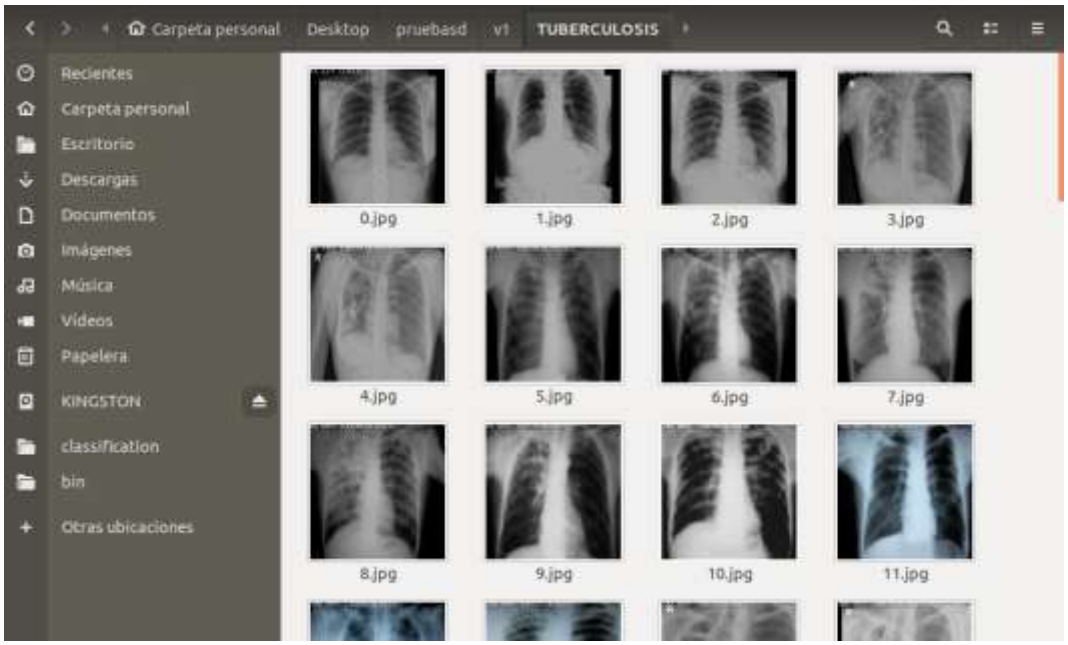

Figura 28. Resultados de diagnóstico del test de neumonía viral

Un total de 21 imágenes radiográficas del tórax del test de tuberculosis fueron clasificados y diagnosticados con los siguientes resultados:

Test de Tuberculosis					
Clases	Covid-19	Bacteriana	Viral	Normal	Tuberculosis
Diagnóstico	0	0	0	0	21

Tabla 9. Diagnósticos de Test de Tuberculosis

Los resultados del diagnóstico médico de las imágenes radiográficas de test tuberculosis del conjunto de datos se puede observar en la Tabla 9.

4.1.2.5. Diagnósticos normal

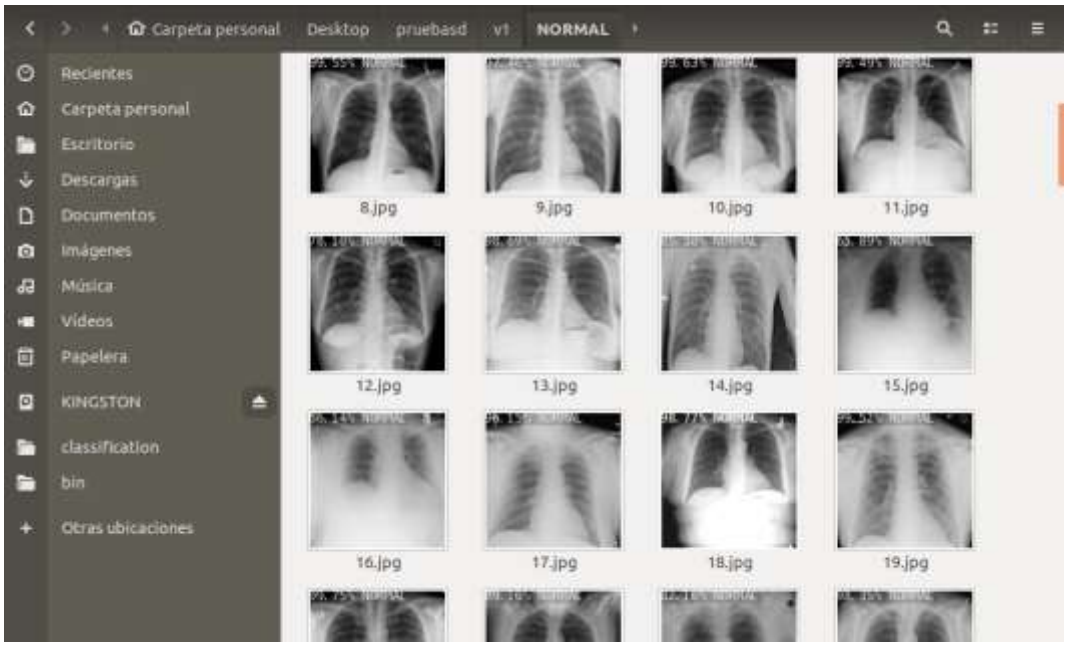

Figura 29. Resultados de diagnóstico del test de normal

Un total de 306 imágenes radiográficas del tórax del test de normal fueron clasificados y diagnosticados con los siguientes resultados:

Test de Normal					
Clases	Covid-19	Bacteriana	Viral	Normal	Tuberculosis
Diagnóstico	1	2	0	303	0

Tabla 10. Diagnósticos de Test de Normal

Los resultados del diagnóstico médico de las imágenes radiográficas de test normal del conjunto de datos se pueden observar en la Tabla 10.

4.1.3. Procesamiento de video en tiempo real

4.1.3.1. Demostración de reconocimiento en cámara

Se demuestra el diagnóstico por camara de video en tiempo real.

Figura 30. Diagnóstico por cámara de video 1

Figura 31. Diagnóstico por cámara de video 1

4.2. CONSTRUCCIÓN DEL SOFTWARE

4.2.1. Recurso Tecnológico

4.2.1.1. Jetson Nano

NVIDIA Jetson Nano Developer Kit es una computadora pequeña y poderosa que le permite ejecutar múltiples redes neuronales en paralelo para aplicaciones como clasificación de imágenes, detección de objetos, segmentación y procesamiento de voz, entre otros. El poder de la IA moderna todo en una plataforma fácil de usar que funciona con tan solo cinco vatios. [33]

Figura 32. NVIDIA Jetson Nano

Esta plataforma ha sido evaluada por Jiménez [34] en su trabajo de fin de grado titulado “Evaluación de la plataforma Nvidia Jetson Nano para aplicaciones de visión artificial”, ha demostrado que la Nvidia Jetson Nano permite trabajar, tanto como con imágenes, como con vídeos, de forma fluida, aunque con ciertas limitaciones en el uso de redes neuronales profundas de uso habitual. En muchas ocasiones, se ha utilizado además la aceleración hardware de la que dispone el dispositivo, reduciendo considerablemente el tiempo de ejecución de algunas aplicaciones, gracias

al uso de CUDA y, también, de TensorRT, tecnologías específicas de Nvidia; obteniendo así un mejor rendimiento. Se han realizado pruebas de rendimiento, cuyo objetivo ha sido conocer las limitaciones que ofrece la Jetson Nano, al tratar con datos tan exigentes como son las imágenes y los vídeos. Los resultados han sido, por lo general, positivos, ya que se han podido instalar todas las herramientas que se han considerado necesarias.

4.2.1.1.1. Nvidia Jetson

NVIDIA Jetson es la plataforma líder mundial para IA en el perímetro. Su computación de alto rendimiento y bajo consumo de energía para el aprendizaje profundo y la visión por computador la convierte en la plataforma ideal para proyectos de computación intensiva. [35]

4.2.1.1.2. Especificaciones técnicas

El hardware de Nvidia Jetson cuenta con las siguientes especificaciones:

Especificaciones	Jetson Nano
CPU	64-bit Quad-core ARM A57 @ 1.43GHz
GPU	128-core NVIDIA Maxwell @ 921MHz
Memoria	4GB 64-bit LPDDR4 @ 1600MHz | 25.6 GB/s
Codificador de video	4Kp30 | (4x) 1080p30 | (2x) 1080p60
Decodificador de video	4Kp60 | (2x) 4Kp30 | (8x) 1080p30 | (4x) 1080p60

Interfaces	
USB	4x USB 3.0 A (Host) | USB 2.0 Micro B (Device)
Cámara	MIPI CSI-2 x2 (conector flexible de 15 posiciones)
Monitor	HDMI | DisplayPort
Redes	Gigabit Ethernet (RJ45)
Inalámbrico	M.2 Key-E with PCIe x1
Almacenamiento	Tarjeta MicroSD (16GB UHS-1 mínimo recomendado)
Otras E/S	(3x) I2C | (2x) SPI | UART | I2S | GPIOs

Tabla 11. Especificaciones técnicas del Jetson Nano

4.2.1.1.3. JetPack

La pila de software Jetson comienza con NVIDIA JetPack SDK, que proporciona un entorno de desarrollo completo e incluye bibliotecas aceleradas CUDA-X y otras tecnologías de NVIDIA para impulsar su desarrollo. JetPack es la solución más completa para crear aplicaciones de IA. Para acelerar su aplicación de IA de extremo a extremo, incluimos TensorRT y cuDNN para acelerar la inferencia de IA, CUDA para acelerar la computación general, VPI para acelerar la visión por computadora y el procesamiento de imágenes, Jetson Multimedia API para acelerar la multimedia, libArgus y V4l2 para acelerar la cámara. [36]

4.2.2. Herramientas Utilizadas

Las herramientas utilizadas (software) en el proyecto serán descriptas a continuación:

4.2.2.1. BalenaEtcher

BalenaEtcher es un programa de código abierto y libre bajo licencia Apache 2.0. Se usa para escribir archivos de imágenes en medios de almacenamiento. Por lo general son imágenes de sistemas operativos como las ISO o IMG y los medios usados suelen ser tarjetas de memoria SD, aunque también admite memorias flash USB. [37]

4.2.2.2. Linux

JetPack incluye el paquete de controladores Jetson Linux con cargador de arranque basado en UEFI, kernel de Linux, entorno de escritorio Ubuntu 18.04, controladores NVIDIA, firmwares necesarios y un conjunto completo de bibliotecas para la aceleración de computación GPU, multimedia y gráficos. [38]

4.2.2.3. Jetson Inference

Jetson Inference es el paquete utilizado para cargar imágenes y las ventanas de visualización para el reconocimiento de las imágenes. Donde se alojan todos los softwares de inferencia. [39]

4.2.2.4. Python

Python es un lenguaje de programación de alto nivel que te permite trabajar rápidamente e integrar los sistemas de manera más eficaz. [40]

4.2.2.4.1. Argparse

Argparse un analizador de opciones de línea de comandos, argumentos y subcomandos, el módulo argparse facilita la escritura de interfaces de línea de comandos, recomendados en la biblioteca estándar de python. El programa define qué argumentos requiere y se descubre cómo analizarlos a partir de sys.argv. [41]

4.2.2.4.2. Gooey

Gooey es una librería de python que decora cualquier programa de línea de comandos de python en una aplicación. Se pueden configurar diferentes estilos y funciones pasando argumentos al decorador. Permite la creación de programas robustos y configurables. [42]

4.2.2.5. Visual Studio Code

Visual Studio Code es un editor de texto y de código fuente desarrollado por Microsoft, multiplataforma que permite trabajar con diversos lenguajes de programación, admite gestionar tus propios atajos de teclado y refactorizar el código. Es gratuito, de código abierto y nos proporciona una utilidad para descargar y gestionar extensiones con las que podemos personalizar y potenciar esta herramienta. [43]

4.2.2.6. Software de aprendizaje profundo

4.2.2.6.1. Cuda

CUDA es una plataforma informática paralela y un modelo de programación desarrollado por NVIDIA para la informática general en unidades de procesamiento gráfico (GPU). [44]

Con CUDA, se pueden acelerar drásticamente las aplicaciones informáticas aprovechando la potencia de las GPU. En las aplicaciones aceleradas por GPU, la parte secuencial de la carga de trabajo se ejecuta en la CPU, que está optimizada para un rendimiento de subproceso único, mientras que la parte intensiva de cómputo de la aplicación se ejecuta en miles de núcleos de GPU en paralelo.

4.2.2.7. Frameworks de Deep Learning

Los frameworks de deep learning (DL) ofrecen componentes básicos para diseñar, entrenar y validar redes neuronales profundas a través de una interfaz de programación de alto nivel. [45]

4.2.2.7.1. PyTorch

PyTorch es una biblioteca de tensores optimizada para el deep learning mediante GPU y CPU. Por lo general, PyTorch se usa como un reemplazo para NumPy para usar el poder de las GPU. Y una plataforma de investigación de Deep Learning que proporciona la máxima flexibilidad y velocidad.

Figura 33. PyTorch biblioteca de tensores para GPU.

PyTorch proporciona tensores que pueden residir en la CPU o en la GPU y acelera enormemente el cálculo. [46]

4.2.2.7.2. ONNX

Intercambio de red neuronal abierta (ONNX) es un formato y estándar abierto creado para representar modelos de Machine Learning y Deep Learning. ONNX define un conjunto común de operadores y un formato de archivo común para permitir que los desarrolladores de IA utilicen modelos con una variedad de frameworks, herramientas, tiempos de ejecución y compiladores. [47]

4.2.2.8. Entrenamiento de Deep Learning

4.2.2.8.1. Dali

La biblioteca de carga de datos (DALI) es una biblioteca de carga de imágenes y aumento de datos acelerada por GPU para optimizar las canalizaciones de datos de marcos de aprendizaje profundo. [48]

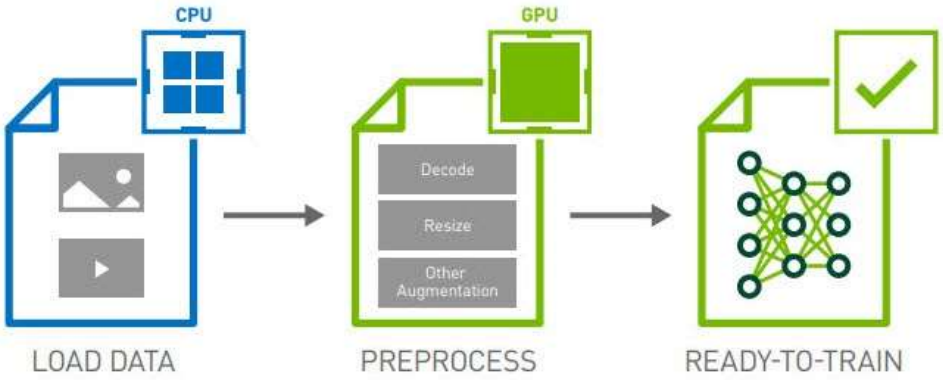

Figura 34. Biblioteca de carga de datos Dali

4.2.2.8.2. CuDNN

CUDA Deep Neural Network (cuDNN) es una biblioteca de alto rendimiento con componentes básicos para aplicaciones de redes neuronales profundas, incluidas primitivas de aprendizaje profundo para convoluciones, funciones de activación y transformaciones de tensor. [48]

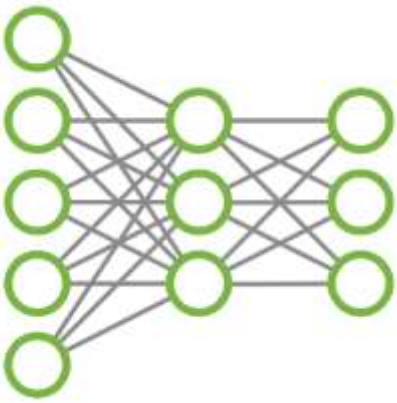

Figura 35. cuDNN biblioteca de primitivas con aceleración de GPU

4.2.2.8.3. TAO Toolkit

TAO Toolkit es un conjunto de herramientas basado en Python para acelerar el entrenamiento de IA mediante la optimización de modelos previamente entrenados y la aplicación del aprendizaje de transferencia para lograr una mayor precisión. [48]

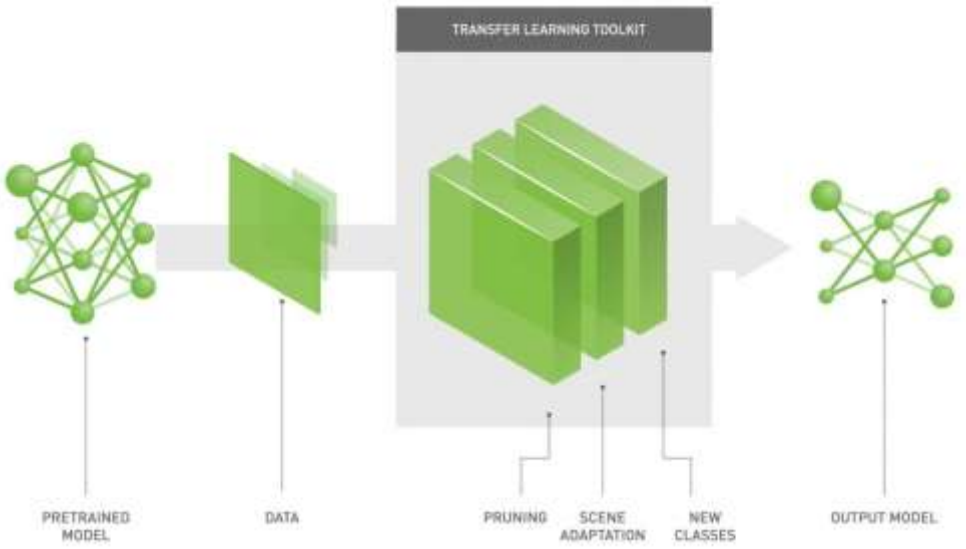

Figura 36. TAO Toolkit

4.2.2.9. Inferencia de aprendizaje profundo

4.2.2.9.1. TensorRT

NVIDIA TensorRT, SDK es un tiempo de ejecución de inferencia de aprendizaje profundo de alto rendimiento para la clasificación de imágenes, segmentación y redes neuronales de detección de objetos. TensorRT se basa en CUDA, incluye un optimizador de inferencia de aprendizaje profundo y tiempo de ejecución que ofrece baja latencia y alto rendimiento para aplicaciones de inferencia. [49]

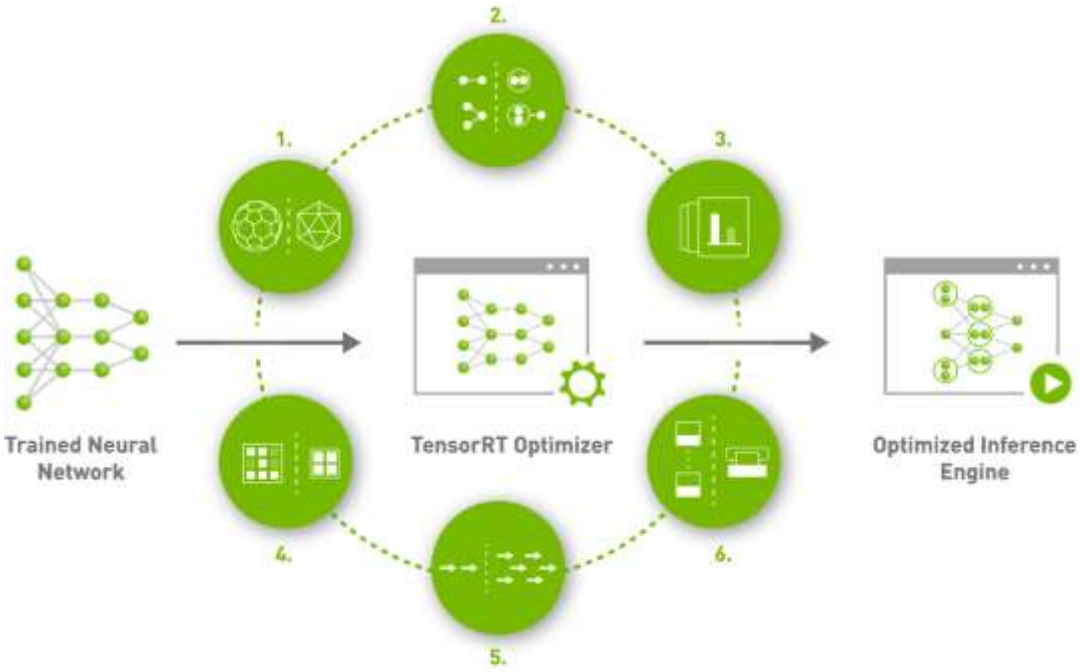

Figura 37. TensorRT optimizador de inferencia

Las aplicaciones basadas en TensorRT funcionan hasta 36 veces más rápido que las plataformas solo de CPU durante la inferencia.

4.2.2.10. OpenGL

OpenGL es una plataforma de interfaz de programación de aplicaciones (API) para la representación en 2D y 3D de gráficos vectoriales. La API se usa generalmente para interactuar con una unidad de procesamiento de gráficos (GPU), para lograr una representación acelerada por hardware. [50]

Sirve para renderizar los gráficos vectoriales con funciones completas en sistemas integrados.

4.2.3. PRUEBA DE LA APLICACIÓN

Para la desarrollo del software que pueda ser utilizado debe implementarse y ejecutarse en el recurso tecnológico Jetson nano, el cual serán instaladas todas las herramientas necesarias para cumplir con la realización del diagnóstico médico del paciente.

4.2.3.1. Manual del usuarios

La elaboración de este manual es con el objetivo de explicar detalladamente toda la funcionalidad del software de apoyo al diagnóstico médico de enfermedades respiratorias en radiografías del tórax.

4.2.3.1.1. Interfaz Gráfica

Al principio el software se ejecutaba por la terminal utilizando línea de comandos (CLI) y luego pasamos a pasar a ejecutar en una interfaz gráfica de usuario (GUI) para los usuarios finales que son los profesionales de la salud del sanatorio, se utilizó la herramienta Gooey de python.

Figura 38. La interfaz gráfica de usuario

Para que el usuario pueda dar el diagnóstico médico debe ingresar primeramente la imagen de rayos x del tórax correspondiente del paciente, en la sección de Radiografía del Tórax del Paciente, presionando el botón de examinar para visualizar los archivos y buscar la ubicación en donde se encuentra la imagen (en la ventana muestra una ayuda para el usuario) con los formatos de imágenes permitidos (jpeg, png, jpg, bmp, tga) y una vez encontrado seleccionar la imagen para cargar al software.

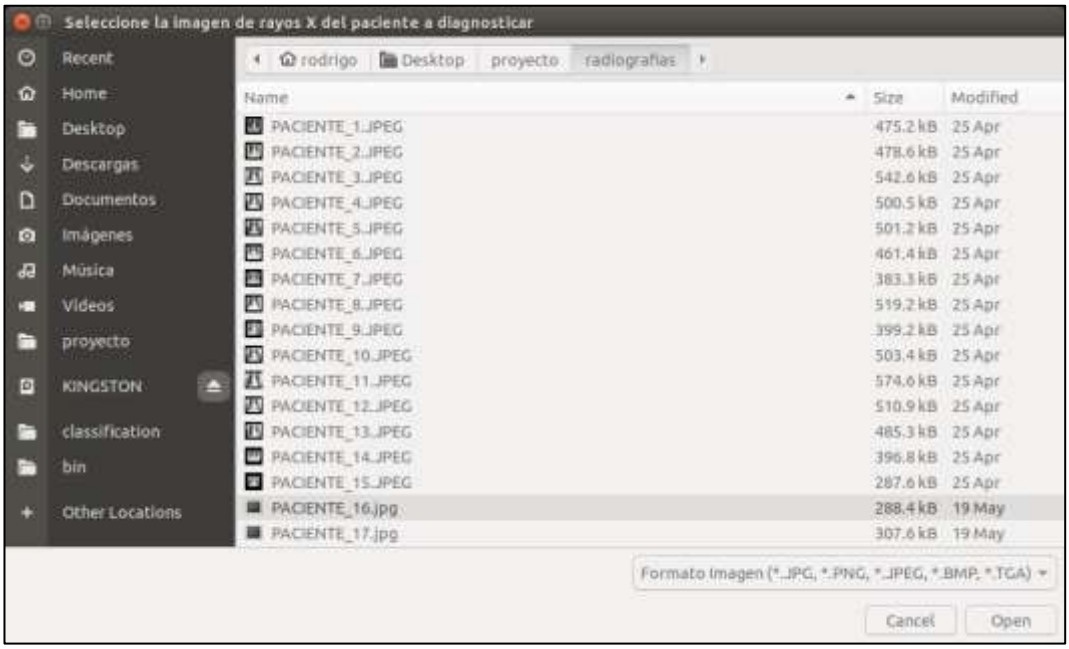

Figura 39. Ingresar la imagen de rayos x del paciente.

Figura 40. Carga de ingreso de la imagen

Luego el usuario debe ubicar donde se guardará el diagnóstico médico, en la sección de Generar el diagnóstico médico, presionando el botón de examinar, seleccionar el directorio o carpeta donde se guardará y escribir el nombre del archivo con el formato de imagen que se quiera guardar, donde se creó un método si el usuario quisiese cambiar de formato de imagen (jpeg, png, jpg, bmp, tga) por sugerencia de los médicos.

La primera imagen ingresada se mantendrá original ya que el sanatorio muestra a sus pacientes su resultado de rayos x por medio de grabación en discos cd o enviados por otros medios electrónicos. Y la imagen guardada con el diagnóstico médico correspondiente se mantendrá en la institución para el estudio de los profesionales de la salud.

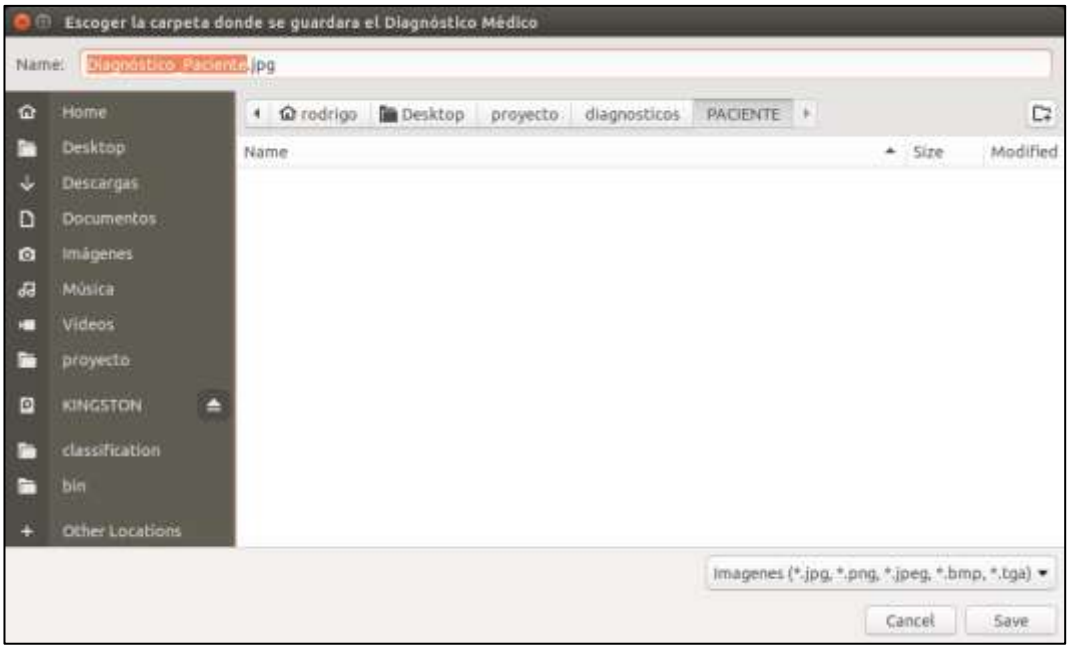

Figura 41. Guardar la imagen para el diagnóstico

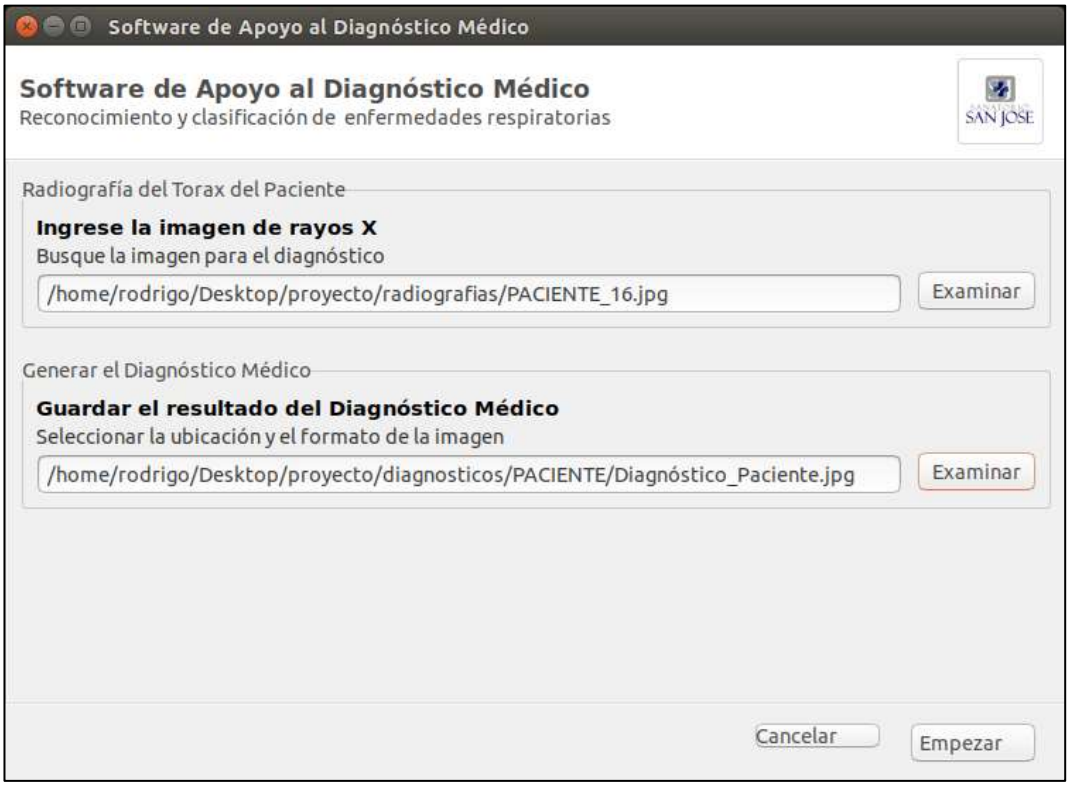

Figura 42. Carga de guardar la imagen

Una vez que el usuario haya completado los campos correspondientes presiona el botón de empezar, si uno o ambos de los campos no son ingresados el programa emite un mensaje de error indicando que el operador debe volver a ingresar sus datos. En caso de no haber errores en la carga de los datos se habilita y empieza la ejecución del mismo para la clasificación de la enfermedad y generar el diagnóstico.

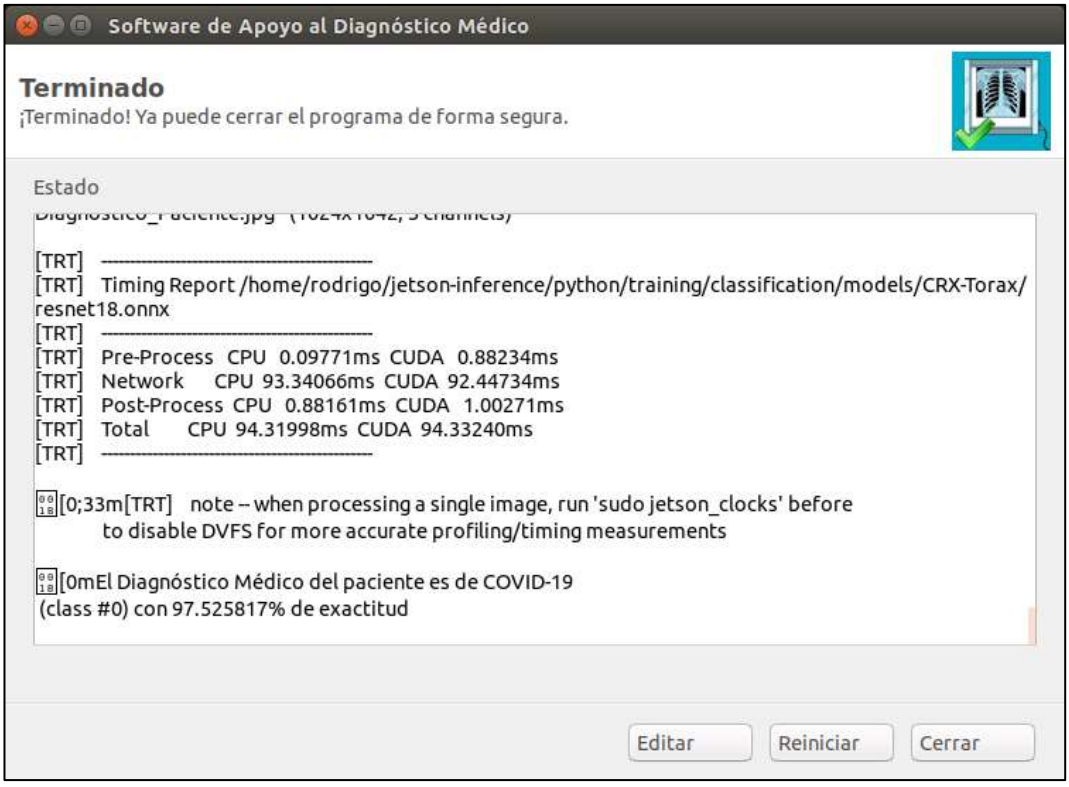

Figura 43. Ejecución y resultado por interfaz gráfica del software.

Una vez terminado con éxito la ejecución del programa el diagnóstico médico aparecerá al final un mensaje del resultado por pantalla. Presionar el botón de cerrar para salir del programa.

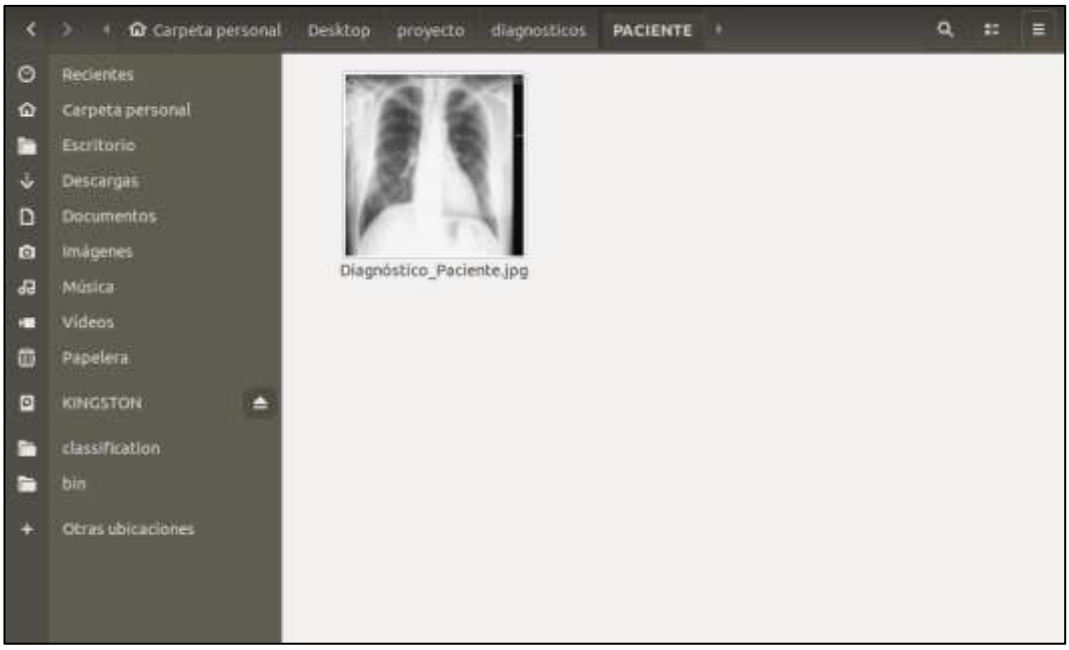

Figura 44. Resultado del Diagnóstico Médico en imagen.

A la vez el usuario podrá observar el diagnóstico médico donde lo guardo, obteniendo estos resultados en solo segundos (aproximadamente 5~30 segundos) con su porcentaje de exactitud de clasificación de la enfermedad.

Figura 45. Diagnóstico Médico del paciente impreso en la imagen.

4.2.4. RECURSOS ECONÓMICOS

4.2.4.1. Costo de Inversión

Son los costos de hardware utilizados para la elaboración del proyecto.

Recursos Tecnológicos			
Cantidad	**Descripción**	**Costo**	**Total**
1	Jetson Nano	1.162.000	1.162.000
1	Gabinete con Coolers	290.000	290.000
1	Tarjeta MicroSD 128GB	150.000	70.000
1	Fuente de alimentación 5V- 4A	193.000	193.000
1	Adaptador de red inalámbrica	80.000	80.000
1	Monitor Touch de 7 pulgadas	769.000	769.000
1	Cable HDMI	100.000	100.000
1	Teclado inalámbrico	100.000	100.000
1	Mouse	60.000	60.000
1	Mouse Pad	10.000	10.000
1	Cámara Logitech	913.500	913.500
1	Adaptador de puertos USB	60.000	60.000
		TOTAL	3.807.500

Tabla 12. Recursos Tecnológicos

CAPÍTULO V

RESULTADOS

Se procesaron un total de 105 muestras de imágenes radiográficas del tórax de pacientes del sanatorio San José de Coronel Oviedo de los cuales los resultados de diagnósticos fueron:

Resultados de la muestra					
Clases	Covid-19	Bacteriana	Viral	Normal	Tuberculosis
Pacientes	56	29	18	0	2

Tabla 13. Resultados de Diagnóstico médico de la muestra

Los resultados del diagnóstico médico de las imágenes radiográficas de la muestra de pacientes con enfermedades respiratorias se pueden observar en la Tabla 13, usando el modelo de deep learning.

CONCLUSIONES

Con el fin de plantear una herramienta de diagnóstico basada en Deep Learning que satisfaga a las necesidades de la problemática, se formularon los objetivos propuestos, los cuales fueron cumplidos en su plenitud, arrojando las siguientes conclusiones:

Por medio de los datos recabados a través de las entrevistas realizadas a los doctores y las investigaciones hechas se pudieron determinar la problemática para el diagnóstico médico, a los profesionales de la salud les resulta complicado y tedioso identificar en las radiografías del tórax que enfermedad padece el paciente, estos inconvenientes pueden generar un erróneo diagnóstico y posterior tratamiento. Con estos datos, se llevó a cabo la investigación de base de datos de imágenes con enfermedades respiratorias que fueron comprobadas por varios profesionales de una comunidad científica para la preparación del conjunto de datos de entrenamiento.

Con la elaboración de un modelo de inteligencia artificial basado en Deep Learning que utiliza redes neuronales profundas que reconoce las patrones y aprende de los datos en el entrenamiento son ideales para el apoyo y soporte a la toma de decisión de un diagnóstico médico que facilite el trabajo, garantice el labor de los profesionales de la salud y dar una rápida y precisa.

El análisis de las herramientas de alto nivel como TensorRT, PyTorch y ONNX permitió el ajuste del modelo para determinar las más acordes para el entrenamiento del conjunto de datos de imágenes de enfermedades respiratorias y optimizar el tiempo para la respuesta al diagnóstico médico en solo segundos, en comparación con los procesos actuales.

Mediante la creación de una interfaz gráfica de usuario se pudo reemplazar las líneas de comandos, facilitando la utilización del software a los profesionales de la salud para su fácil entendimiento, detallando por

pantalla lo que el usuario debe realizar; como debe de cargar las imágenes de rayos x y realizar el diagnóstico médico de su paciente.

Con todo lo mencionado se concluyó que la implementación del modelo de inteligencia artificial basado en Deep Learning para el apoyo al diagnóstico médico al sanatorio San José de Coronel Oviedo permitirá mejorar la atención médica de la institución y satisfacer las necesidades mencionadas.

RECOMENDACIONES

Las recomendaciones para obtener un modelo de aprendizaje más robusto que puedan dar más soluciones, re recomienda que:

La inclusión de más imágenes radiográficas del tórax, si alguna de estas enfermedades posee nuevos síntomas o niveles de infección, posibles nuevas variantes del covid-19.

Agregar otras enfermedades respiratorias para poder ampliar el aprendizaje del modelo y poder realizar más soluciones para los profesionales de la salud.

Involucrar a otras instituciones de la salud con un proceso de trabajo similar e implementar para poder mejorar la base de conocimiento y ajustar el modelo de inteligencia artificial.

Aplicar otras herramientas de diagnóstico de enfermedades como la tomografía computarizada y resonancia magnética.

Bibliografía

[1] L. Á. C. Santamaría, Reconocimiento de patrones en imágenes médicas por medio de redes neuronales convolucionales, Puebla, 2019.

[2] M. A. Huamaní Príncipe, SISTEMA EXPERTO DE APOYO PARA EL PROCESO DE DIAGNÓSTICO DE ENFERMEDADES RESPIRATORIAS EN LA CLÍNICA SAN BARTOLOME SAC, Lima, 2021.

[3] T. Shiva Singh , S. Ansh , J. Gaurav y G. Richa , «Diagnóstico de enfermedades basado en aprendizaje profundo utilizando clasificación de imágenes,» de *11ª Conferencia Internacional sobre Computación en la Nube, Ciencia e Ingeniería de Datos (Confluence)*, Noida, India, 2021.

[4] SAS Institute Inc., «SAS Sistema de Análisis Estadístico,» Software de Analítica & Soluciones, 2022. [En línea]. Disponible en: https://www.sas.com/es_cl/insights/analytics/what-is-artificial-intelligence.html.

[5] M. Jos, «digitalbizmagazine.com,» MathWorks, 3 enero 2022. [En línea]. Disponible en: https://www.digitalbizmagazine.com/workflow-de-la-inteligencia-artificial/.

[6] The MathWorks Inc.©, «mathworks.com,» Entorno de computación más fácil y productivo para ingenieros y científicos., 2022. [En línea]. Disponible en: https://es.mathworks.com/discovery/artificial-intelligence.html.

[7] SAS Institute Inc., «sas.com,» Software de Analítica & Soluciones, 2022. [En línea]. Disponible en: https://www.sas.com/es_cl/insights/analytics/neural-networks.html.

[8] NVIDIA , «NVIDIA DEVELOPER,» 2022. [En línea]. Disponible en: https://developer.nvidia.com/deep-learning.

[9] The MathWorks, Inc., «es.mathworks.com,» Diseño de modelos de Inteligencia Artificial y sistemas dirigidos por Inteligencia Artificial, 2022. [En línea]. Disponible en: https://es.mathworks.com/discovery/deep-learning.html.

[10] R. Ceron, «IBM,» 26 12 2019. [En línea]. Disponible en: https://www.ibm.com/blogs/systems/mx-es/2019/12/inteligencia-artificial-hoy-datos-entrenamiento-e-infrerencias/.

[11] SAS, «Soluciones y Software de analisis,» SAS Institute Inc, 2022. [En línea]. Disponible en: https://www.sas.com/en_us/insights/analytics/deep-learning.html.

[12] ScienceDirect, «www.sciencedirect.com,» 2022. [En línea]. Disponible en: https://www.sciencedirect.com/topics/engineering/deep-neural-network.

[13] The MathWorks, Inc., «es.mathworks.com,» Desarrollo de software de cálculo matemático para ingenieros, 2022. [En línea]. Disponible en: https://es.mathworks.com/discovery/convolutional-neural-network-matlab.html.

[14] SAS, «Software de Analítica & Soluciones,» SAS Institute Inc., 2022. [En línea]. Disponible en: https://www.sas.com/es_cl/insights/analytics/computer-vision.html.

[15] J. L. Vázquez, «Facultad Politécnica - UNA,» 2022. [En línea]. Disponible en: https://www.pol.una.py/wp-content/uploads/2022/07/Brochure-Diplomados-Procesamiento-digital-imagenes-1.pdf.

[16] D. Retana Rivero, «Paradigma Digital,» Think Big, 2020. [En línea]. Disponible en: https://www.paradigmadigital.com/dev/edge-computing-con-nvidia-jetson-nano/.

[17] Chacaltana, Interviewee, *Enfermedades respiratorias.* [Entrevista]. 2017.

[18] OMS, «Organización mundial de la salud,» 9 12 2019. [En línea]. Disponible en: https://www.who.int/es/news/item/09-12-2020-who-reveals-leading-causes-of-death-and-disability-worldwide-2000-2019.

[19] OMS, «Organización Mundial de la Salud,» Tablero de Emergencias Sanitarias de la OMS, 2 8 2022. [En línea]. Disponible en: https://covid19.who.int/.

[20] OMS, «Organización mundial de la salud,» OMS Paraguay, 2 8 2022. [En línea]. Disponible en: https://www.who.int/countries/pry/.

[21] NIH, «MedlinePlus,» Instituto Nacional del Corazón, los Pulmones y la Sangre, 2022. [En línea]. Disponible en: https://medlineplus.gov/spanish/pneumonia.html.

[22] P. MOONEY, «Kaggle,» 6 enero 2018. [En línea]. Disponible en: https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia.

[23] Mayo Foundation for Medical Education, «Mayo Clinic,» 2022. [En línea]. Disponible en: https://www.mayoclinic.org/es-es/diseases-conditions/pneumonia/symptoms-causes/syc-20354204?p=1.

[24] OMS, «Organización mundial de la salud,» OMS, 2022. [En línea]. Disponible en: https://www.who.int/health-topics/coronavirus.

[25] «medlineplus.gov,» A.D.A.M, 24 12 2020. [En línea]. Disponible en: https://medlineplus.gov/spanish/ency/article/000077.htm.

[26] medlineplus, «medlineplus.gov,» NIH Biblioteca nacional de medicina, 2022. [En línea]. Disponible en: https://medlineplus.gov/spanish/diagnosticimaging.html.

[27] radiologyinfo, «radiologyinfo.org,» RTAnswers.org, [En línea]. Disponible en: https://www.radiologyinfo.org/es/info/chestrad.

[28] NIH, «MedlinePlus,» Biblioteca Nacional de Medicina, 2022. [En línea]. Disponible en: https://medlineplus.gov/spanish/ency/article/003804.htm.

[29] C. Espinoza Montes, Metodología de la investigación tecnológica, pensando en sistemas, Huancayo - Perú, 2010.

[30] Wikipedia, «wikipedia.org,» Fundación Wikimedia, Inc., , 2022. [En línea]. Disponible en: https://es.wikipedia.org/wiki/Kaggle.

[31] R. TAWSIFUR , «kaggle.com,» 2022. [En línea]. Disponible en: https://www.kaggle.com/datasets/tawsifurrahman/covid19-radiography-database.

[32] R. TAWSIFUR , «kaggle.com,» 2022. [En línea]. Disponible en: https://www.kaggle.com/datasets/tawsifurrahman/tuberculosis-tb-chest-xray-dataset.

[33] NVIDIA DEVELOPER, «NVIDIA,» Jetson Nano Developer Kit, 2019. [En línea]. Disponible en: https://developer.nvidia.com/embedded/jetson-nano-developer-kit.

[34] N. Jiménez Varela, Evaluación de la plataforma Nvidia Jetson Nano para aplicaciones de visión artificial, Madrid, 2021.

[35] NVIDIA, «NVIDIA DEVELOPER,» Jetson, 2019. [En línea]. Disponible en: https://developer.nvidia.com/embedded/faq.

[36] NVIDIA, «NVIDIA DEVELOPER,» NVIDIA JETPACK, 2022. [En línea]. Disponible en: https://developer.nvidia.com/embedded/develop/software.

[37] Isaac, «Hardware libre,» 2022. [En línea]. Disponible en: https://www.hwlibre.com/etcher/.

[38] NVIDIA, «NVIDIA DEVELOPER,» NVIDIA JetPack, 2022. [En línea]. Disponible en: https://docs.nvidia.com/jetson/jetpack/introduction/index.html.

[39] F. Dustin , «github,» 2022. [En línea]. Disponible en: https://rawgit.com/dusty-nv/jetson-inference/python/docs/html/python/jetson.inference.html.

[40] Python, «Python.org,» 2022. [En línea]. Disponible en: https://www.python.org/.

[41] Python, «python.org,» The Python Standard Library, 2022. [En línea]. Disponible en: https://docs.python.org/3/library/argparse.html.

[42] C. Kieh, «github,» 2022. [En línea]. Disponible en: https://github.com/chriskiehl/Gooey/.

[43] AITANA SOLUCIONES, «AITANA,» Tecnología, Innovación, Compromiso, 2018. [En línea]. Disponible en: https://blog.aitana.es/2018/10/16/visual-studio-code/.

[44] NVIDIA, «NVIDIA DEVELOPER,» 2022. [En línea]. Disponible en: https://developer.nvidia.com/cuda-zone.

[45] NVIDIA, «developer.nvidia.com,» Framework DL, 2022. [En línea]. Disponible en: https://developer.nvidia.com/deep-learning-frameworks.

[46] pytorch.org, «github.com,» 2022. [En línea]. Disponible en: https://github.com/pytorch/pytorch.

[47] ONNX, «onnx.ai,» The Linux Foundation, 2022. [En línea]. Disponible en: https://onnx.ai/.

[48] NVIDIA, «NVIDIA DEVELOPER,» 2022. [En línea]. Disponible en: https://developer.nvidia.com/deep-learning-software.

[49] NVIDIA, «NVIDIA DEVELOPER,» 2022. [En línea]. Disponible en: https://developer.nvidia.com/tensorrt.

[50] OpenGL, «opengl .org,» 2020. [En línea]. Disponible en: https://hmong.es/wiki/OpenGL_1.

ANEXO

ANEXO 1

Nota de solicitud

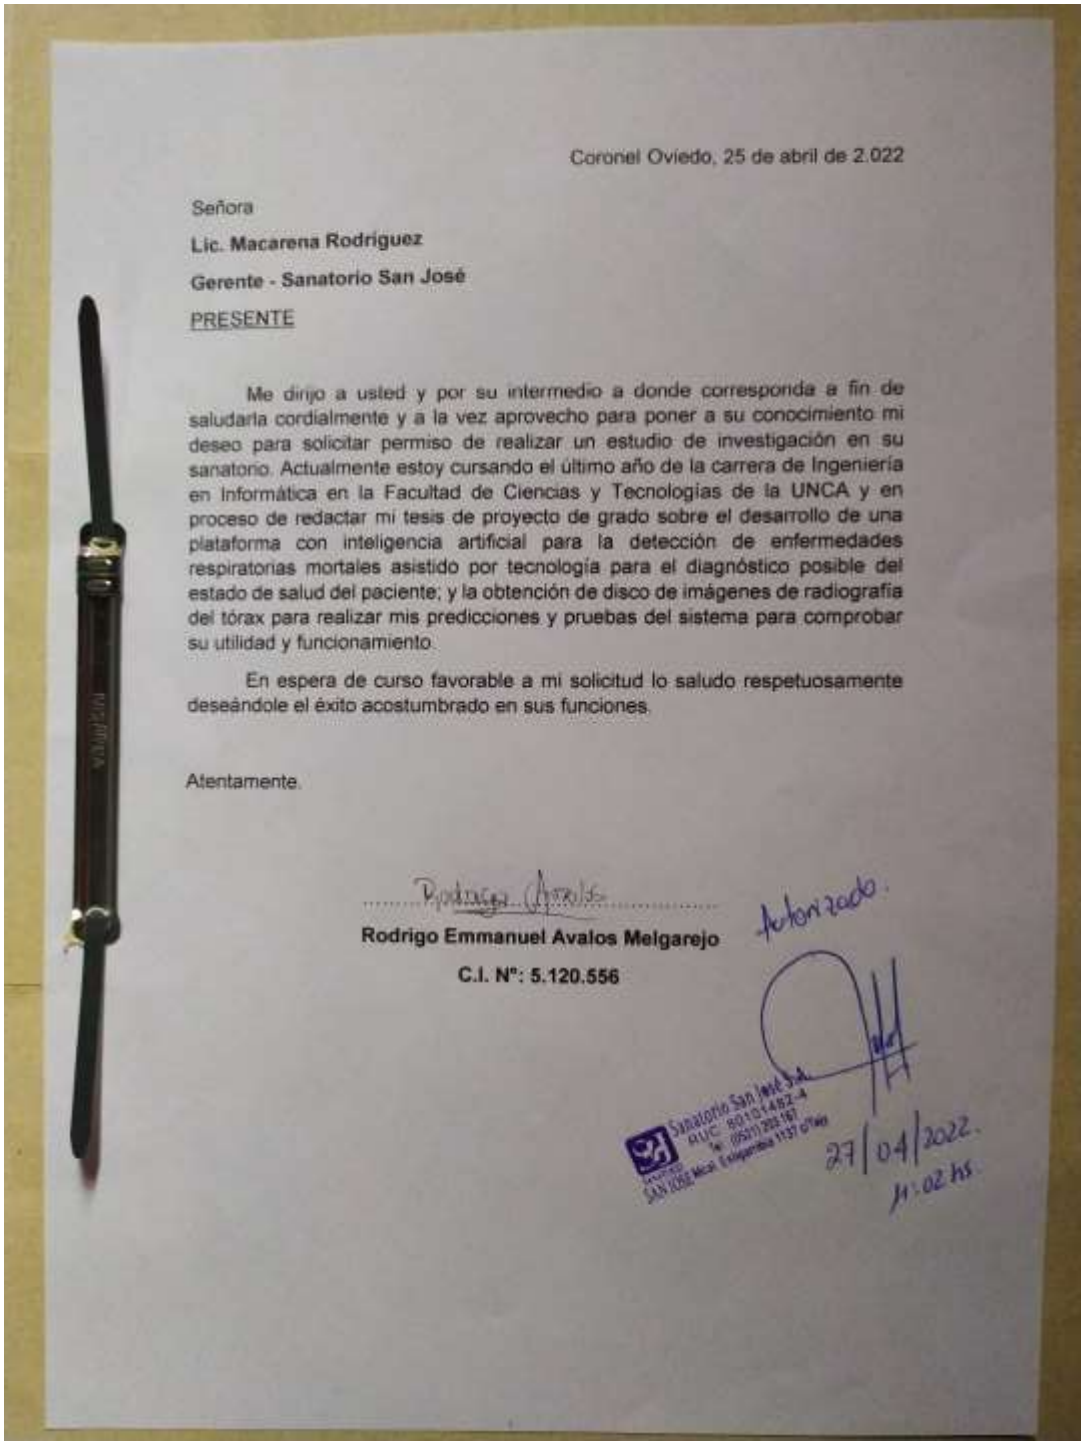

Coronel Oviedo, 25 de abril de 2.022

Señora

Lic. Macarena Rodriguez

Gerente - Sanatorio San José

PRESENTE

Me dirijo a usted y por su intermedio a donde corresponda a fin de saludarla cordialmente y a la vez aprovecho para poner a su conocimiento mi deseo para solicitar permiso de realizar un estudio de investigación en su sanatorio. Actualmente estoy cursando el último año de la carrera de Ingeniería en Informática en la Facultad de Ciencias y Tecnologías de la UNCA y en proceso de redactar mi tesis de proyecto de grado sobre el desarrollo de una plataforma con inteligencia artificial para la detección de enfermedades respiratorias mortales asistido por tecnología para el diagnóstico posible del estado de salud del paciente; y la obtención de disco de imágenes de radiografía del tórax para realizar mis predicciones y pruebas del sistema para comprobar su utilidad y funcionamiento.

En espera de curso favorable a mi solicitud lo saludo respetuosamente deseándole el éxito acostumbrado en sus funciones.

Atentamente.

Rodrigo Emmanuel Avalos Melgarejo

C.I. N°: 5.120.556

Autorizado.

27/04/2022.

Figura 46. Nota de solicitud al sanatorio

ANEXO 2

Área de Radiografía

Figura 47. Área de Radiografía 1

Figura 48. Área de Radiografía 2

Figura 49. Área de Radiografía 3

Figura 50. Área de Radiografía 4

ANEXO 3

Área de Servicio de Diagnóstico por imágenes

Figura 51. Servicio de Diagnóstico por imágenes - 1

Figura 52. Servicio de Diagnóstico por imágenes - 2

ANEXO 4

Disco RX de Tórax de paciente

Figura 53. Disco RX de Tórax PA - 1

Figura 54. Disco RX de Tórax PA - 2

Figura 55. Imagen de rayos X de Tórax del paciente

ANEXO 5

Imágenes de radiografías del Tórax de Pacientes del sanatorio.

Figura 56. Radiografía del tórax frontal

Figura 57. Radiografía del tórax paciente acostado

Figura 58. Radiografía del tórax paciente sentado

ANEXO 6

Jetson nano y componentes de desarrollo.

Figura 59. Equipos de desarrollo