

UNIVERSIDAD CATÓLICA SANTO TORIBIO DE MOGROVEJO
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA DE SISTEMAS Y COMPUTACIÓN



Sistema inteligente basado en deep learning para el apoyo en el diagnóstico del cáncer del pulmón para el Hospital Regional de Lambayeque

**TESIS PARA OPTAR EL TÍTULO DE
INGENIERO DE SISTEMAS Y COMPUTACIÓN**

AUTOR

Andy Alberto Torres Sanchez

ASESOR

Edwar Glorimer Lujan Segura

<https://orcid.org/0000-0003-0663-4189>

Chiclayo, 2025

Sistema inteligente basado en deep learning para el apoyo en el diagnóstico del cáncer de pulmón para el Hospital Regional de Lambayeque

PRESENTADA POR
Andy Alberto Torres Sanchez

A la Facultad de Ingeniería de la
Universidad Católica Santo Toribio de Mogrovejo
para optar el título de

INGENIERO DE SISTEMAS Y COMPUTACIÓN

APROBADA POR

María Ysabel Aranguri García
PRESIDENTE

Ricardo David Imán Espinoza
SECRETARIO

Edwar Glorimer Lujan Segura
VOCAL

Dedicatoria

A mis padres por su apoyo incondicional y haberme brindado todo lo necesario para poder realizar lo que me proponga.

A mis amigos, quienes con sus palabras de aliento y su comprensión me acompañaron en los momentos difíciles y celebraron cada logro a mi lado.

Agradecimientos

A mis padres por estar conmigo siempre en toda mi etapa como estudiante, por haberme impulsado a seguir adelante con sus palabras de aliento y su ejemplo de esfuerzo y perseverancia.

A las instituciones y persona que me brindaron los recursos para hacer realidad esta tesis.

Sistema inteligente basado en deep learning para el apoyo en el diagnóstico del cáncer de pulmón para el Hospital Regional de Lambayeque

INFORME DE ORIGINALIDAD

14%	13%	2%	4%
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	tesis.usat.edu.pe Fuente de Internet	3%
2	www.coursehero.com Fuente de Internet	1%
3	liora.io Fuente de Internet	1%
4	www.researchgate.net Fuente de Internet	1%
5	idoc.pub Fuente de Internet	< 1%
6	oa.upm.es Fuente de Internet	< 1%
7	www.itba.edu.ar Fuente de Internet	< 1%
8	Submitted to Universidad Tecnica De Ambato- Direccion de Investigacion y Desarrollo , DIDE Trabajo del estudiante	< 1%
9	ddd.uab.cat Fuente de Internet	< 1%
10	docplayer.es Fuente de Internet	< 1%
11	es.slideshare.net Fuente de Internet	< 1%
12	repositorio.uchile.cl Fuente de Internet	< 1%

Índice

Resumen	5
Abstract.....	6
Introducción.....	7
Revisión de literatura.....	9
Materiales y métodos.....	14
Resultados y discusión.....	16
Conclusiones.....	21
Recomendaciones	22
Referencias	23
Anexos.....	25

Resumen

La presente investigación ha demostrado que un sistema inteligente basado en aprendizaje profundo ha logrado con éxito la detección de nódulos pulmonares en el Hospital Regional de Lambayeque. El objetivo principal fue el desarrollo de un sistema inteligente para apoyar el diagnóstico del cáncer de pulmón. Los objetivos específicos incluyeron la determinación de un algoritmo de preprocesamiento de imágenes, la selección y aplicación de un modelo de aprendizaje automático adecuado, el diseño de un modelo computacional para la detección de nódulos pulmonares, y la validación de su precisión.

Se utilizó la metodología *crisp-dm* para el desarrollo del modelo, con fases que incluyeron la comprensión del negocio y los datos, la preparación de estos, el modelado y la evaluación del modelo. Se eligieron redes neuronales convolucionales (CNN) por su capacidad de aprender patrones complejos en las imágenes médicas. El modelo entrenado alcanzó una precisión del 91.89%, demostrando una alta eficacia en la detección de nódulos pulmonares. El sistema, además de permitir un diagnóstico temprano, tiene el potencial de agilizar el proceso de análisis médico, reduciendo la carga de trabajo de los radiólogos y mejorando la atención a los pacientes.

Palabras clave: Cáncer de pulmón, Redes neuronales, Nódulos pulmonares, Aprendizaje profundo, Precisión, Sensibilidad.

Abstract

This research has shown that an intelligent system based on deep learning has successfully achieved pulmonary nodule detection at the Lambayeque Regional Hospital. The main objective was to develop an intelligent system to support the diagnosis of lung cancer. The specific objectives included determining an image preprocessing algorithm, selecting and applying a suitable machine learning model, designing a computational model for detecting pulmonary nodules, and validating its accuracy.

The crisp-dm methodology was used to guide system development, with phases including business and data understanding, data preparation, modeling, and model evaluation. Convolutional Neural Networks (CNN) were chosen due to their ability to learn complex patterns in medical images. The trained model achieved an accuracy of 91.89%, demonstrating high effectiveness in detecting pulmonary nodules. The system, in addition to enabling early diagnosis, has the potential to streamline the medical analysis process, reducing the workload on radiologists and improving patient care.

Keywords: Pulmonary cancer, Neural networks, Pulmonary nodules, Deep learning, Accuracy, Sensitivity.

Introducción

El cáncer se le conoció como una enfermedad que se caracteriza por un crecimiento descontrolado de células, este crecimiento anormal podía iniciarse en cualquier parte del cuerpo y ocurría cuando el proceso natural de división y crecimiento de las células se descontrolaba. Usualmente las células dañadas envejecidas o muertas se reemplazan por células nuevas que están formadas a partir de células existentes. Sin embargo, este proceso en el cáncer las células que están dañadas se volvían anormales y se formaban células adicionales que no son necesarias, lo que da lugar a la formación de masas llamadas tumores, cuando estas células anormales se originan en el pulmón se le conoció como cáncer de pulmón. [1]. De acuerdo con los datos de globocan en 2022, el cáncer de pulmón continuó siendo uno de los principales a nivel mundial, este cáncer fue el más común, con un aproximado de 2.5 millones de casos nuevos en todo el mundo, esto representa el 12.4% de todos los diagnósticos de cáncer lo cual lo hace responsable de 1.8 millones de fallecimientos, esto representa el 18.7% de todas las muertes a nivel global [2]. En España el índice de muerte por cáncer está centrado en el pulmón, con una incidencia notablemente mayor en hombres que en mujeres. Mientras que en estados unidos las estadísticas de la sociedad americana contra el cáncer estimaron que en 2023 se diagnosticaran 238,340 casos de cáncer de pulmón con 127,070 muertes. En este país el cáncer de pulmón mayormente afecta a personas mayores de 65 años [4]. Estos datos nos reflejan que, aunque no es el más común, el cáncer de pulmón sigue siendo el que representa la tasa de mortalidad más alta, lo que subraya la importancia de una detección temprana. Por este motivo, y el alto grado de dificultad de la estructura del pulmón se complica su análisis, la identificación oportuna de nódulos pulmonares es una de las áreas investigadas en el análisis de imágenes médicas.

La situación del Hospital Regional de Lambayeque es un reflejo de esta problemática, en el área de tomografía contaba con un radiólogo por turnos de 6 horas, mañana o tarde, se encarga de realizar la lectura de las tomografías con o sin contraste, dependiendo de la patología que se va a diagnosticar. Además, el radiólogo contaba con el apoyo de un médico de radiología quien asistía en algunas tareas. A pesar de sus esfuerzos, los médicos tenían mucha carga de trabajo con un promedio de 15 procedimientos tomográficos por turno, esto afecto la capacidad del hospital para realizar diagnósticos tempranos de los nódulos pulmonares, un elemento crítico para el tratamiento efectivo del cáncer de pulmón. La

complejidad de la interpretación de imágenes pulmonares debido a la estructura pulmonar y la variabilidad de los nódulos se requería una mayor precisión en la lectura de las tomografías. Esto hacía evidente la necesidad e implementar una herramienta tecnológica que apoyara al especialista en la detección de nódulos pulmonares, especialmente en tomografías torácicas sin contraste. Dada la rapidez con la que las enfermedades afectan a las personas, la ciencia ha encontrado una forma - que el uso de redes artificiales en términos de monitoreo, programas, pruebas y velocidad de respuesta inmediata que puede combatir esta enfermedad [5]. El Deep learning es una de las tecnologías de aprendizaje automático (machine learning) más importante, través de redes neuronales artificiales. Las redes constan de docenas o incluso cientos de capas de neuronas, cada una de las cuales recibe e interpreta información de la capa anterior [6]. Así mismo, se pueden ver el gran problema que ocasiona el cáncer de pulmón, por lo que es importante hacerse la siguiente pregunta: ¿cómo apoyar el diagnóstico de cáncer de pulmón en el Hospital Regional de Lambayeque? Debido a este problema, se propone crear un sistema inteligente que apoye el diagnóstico de cáncer de pulmón y pueda ayudar al radiólogo a analizar las tomografías computarizadas de pacientes que presenten problemas respiratorios.

El objetivo principal de esta investigación es construir un sistema inteligente que apoye el diagnóstico del cáncer en el hospital Regional de Lambayeque. Para alcanzar este objetivo se identificaron varios objetivos específicos: determinar el algoritmo de preprocesamiento de imágenes para la extracción de datos de las tomografías computarizadas, evaluar la precisión de algoritmos de aprendizaje automático en la detección de nódulos pulmonares, diseñar un modelo computacional que utilice imágenes digitales para detectar nódulos y validar la eficacia de este modelo. La implementación del sistema no solo pretende mejorar la precisión diagnóstica, también pretende reducir la carga de trabajo de los radiólogos.

Desde el punto de vista científico el desarrollo de justifica por la necesidad de avanzar en la detección de nódulos pulmonares, aportando en la ciencia de la salud con esta herramienta innovadora. Económicamente el sistema se plantea como una alternativa accesible frente a otras opciones costosas, disminuyendo el tiempo de espera y aumentando los pacientes atendidos. Desde el ámbito social, hay un impacto positivo en varios niveles, para los pacientes la implementación de esta tecnología les brinda un acceso más rápido a los diagnósticos precisos, lo cual es esencial para el tratamiento de manera inmediata y por ende para mejorar la calidad de vida del paciente. Al reducir la incertidumbre y el tiempo de espera los pacientes tendrán un proceso de diagnóstico menos estresante y más confiable. Para los

especialistas de salud, en este caso los radiólogos, esta herramienta les permitirá una reducción de carga de trabajo al automatizar el análisis de las imágenes y así podrán dedicar más tiempo en la interpretación de casos complejos y en la atención personalizada de cada paciente. Finalmente, desde el ámbito tecnológico, se justifica por la integración de tecnologías de software y hardware, lo que les permitirá un desarrollo eficiente y efectivo del sistema para el apoyo a los radiólogos en su labor.

Revisión de literatura

Para este estudio, se han tenido en cuenta los siguientes antecedentes. Yacolca Huaman [7] La situación problemática de su investigación es el impacto negativo que el cáncer de mama tiene en las mujeres a nivel mundial, según la Organización Mundial de la Salud(OMS) en el año que se desarrolló el estudio, cerca de 627,000 mujeres fallecieron debido a esta enfermedad. Como alternativa de solución, el autor propuso el desarrollo de un algoritmo que pudiera identificar el tejido mamario utilizando criterios de atipia celular, este algoritmo se integró dentro del sistema computarizado basado en la escala de Nottingham, una metodología usada para la evaluación de cáncer de mama. Para el desarrollo de este algoritmo, se usaron dos bases de datos: Brecahad, que contiene 162 imágenes de cáncer de mama con observaciones detalladas y Mitos-Atypia, la cual almacena imágenes correspondientes a campos de alta potencia(HPF) con observaciones de atipia nuclear y mitosis. Además, se implementaron las redes neuronales convolucionales para entrenar el modelo, porque estas son reconocidas por su capacidad de aprender patrones complejos en imágenes. Por ultimo los resultados obtenidos mostraron que el desarrollo del algoritmo logro un 84.3% de precisión permitiendo reducir la carga de trabajo al patólogo.

Ramon Cueva [8] La investigación se enfoca en la problemática común en muchas de las instituciones de salud, la carga de trabajo sobre un radiólogo que se encarga de analizar las mamografías de una gran cantidad de pacientes. Esto genera una demora en el diagnostico de tumores de mama, lo que afecta en la detección temprana y por supuesto el tratamiento oportuno de la enfermedad, como propuesta de solución de desarrollo un sistema inteligente para el análisis de mamografías, cuya finalidad es asistir al radiólogo y optimizar el diagnostico. Para esta solución de implemento dos metodologías: primero, las etapas de Machine Learning para crear el modelo que pueda interpretar las imágenes de las

mamografías y segundo la metodología RUP para la creación y desarrollo del sistema inteligente. Para la recolección de datos se usaron dos bases de datos relevantes: Mini-Mias que cuenta con 322 imágenes mamográficas de senos sin anomalías y Ddsm que cuenta 2500 exámenes mamográficos con información clínica del paciente y dos imágenes por cada mama, para el entrenamiento del modelo se usaron redes neuronales convolucionales, las cuales nos permiten una clasificación precisa de las imágenes que presentan tumores y las que no. Los resultados fueron validados por la matriz de confusión obteniendo una precisión del 93.5% y una exactitud de 88.5%, lo cual muestra la eficacia del sistema sobre la clasificación de mamografías y el potencial para asistir a los radiólogos en el diagnóstico temprano de tumores de mama.

Pérez Lorenzo [9] La problemática que aborda esta investigación es la dificultad de identificar lesiones cutáneas para la detección de un melanoma, que es uno de los tipos de cáncer de piel más agresivos. Los métodos tradicionales para el diagnóstico pueden ser dependientes sobre la experiencia del médico, esto le genera una gran carga de trabajo al especialista, por eso es necesario contar con herramientas automatizadas que puedan mejorar la precisión del diagnóstico. La propuesta de solución fue un sistema que emplea los métodos de aprendizaje profundo basado en la técnica de transferencia de aprendizaje. Debido a que los recursos de hardware eran limitados y entrenar un modelo desde cero requiere de un tiempo considerable, optaron por utilizar redes preentrenadas como Alexnet, Resnet y Vgg. Estas redes son seleccionadas por la capacidad que tienen de identificar patrones complejos en imágenes médicas, los datos que se usaron para el entrenamiento del modelo fueron 10,000 imágenes de manchas cutáneas referidas al melanoma, las imágenes están en formato JPG y con una resolución de 660 x 450 píxeles, estas imágenes fueron procesadas y entrenadas en la plataforma Pytorch usando bibliotecas Keras y Tensorflow para la facilidad de manipular los datos. Para los resultados, el sistema fue capaz de detectar el melanoma de la piel de manera precisa, el modelo obtuvo una precisión del 85%, proporcionando un diagnóstico temprano y apoyando en la toma de decisiones a los médicos, la implementación de este sistema permitió mejorar la precisión del diagnóstico, especialmente en los casos donde el análisis manual es propenso a errores.

Catalan [21] En la región de Loreto, se nos presenta una situación problemática en el ámbito de la salud por el motivo sobre la precariedad de los servicios sanitarios. Esta consecuencia nos ha llevado a un aumento sobre las enfermedades crónicas como la diabetes y la hipertensión, lo cual nos ha generado un problema de salud pública significativa. Como

propuesta de solución para abordar este problema, se propuso el desarrollo de un sistema inteligente que permita un diagnóstico temprano para las enfermedades renales por medio de la identificación de patrones en las imágenes de muestras de orina, este sistema se basó en redes neuronales convolucionales, estas redes fueron entrenadas con imágenes de los pacientes, una de las principales características de esta solución es la posibilidad de que los pacientes puedan interactuar con el sistema a través de sus dispositivos móviles, esto les permite enviar imágenes desde sus hogares o también de los centros médicos para el análisis oportuno, este enfoque innovador busca mejorar la precisión del diagnóstico, pero también busca ampliar el acceso a los servicios de salud en la región de Loreto, donde ya sabemos la infraestructura médica es limitada. Los resultados de este sistema fueron muy satisfactorios, logrando una precisión del 97% y una sensibilidad del 98% en la detección de diagnósticos de enfermedades renales, clasificando con efectividad entre casos de pacientes sanos y aquellos que presentan patologías. La implementación de esta herramienta tecnológica permitió mejorar la eficiencia de los procesos de análisis médico y contribuyó significativamente a la reducción de la carga de trabajo de los especialistas en la región.

Aamir et al. [22] La investigación nos presenta una problemática que existe para poder detectar los tumores cerebrales usando las imágenes de resonancia magnética, un proceso con mucha dificultad debido a la alta resolución de las imágenes médicas y naturaleza variable. El diagnóstico manual que brindan los radiólogos no solo es lento, sino también es susceptible al cansancio del especialista, el cual puede cometer errores. Para dar solución a este problema, los autores desarrollaron un modelo que se basa en las redes neuronales convolucionales que nos permitirá automatizar el análisis de las imágenes, se usaron un conjunto de datos compuesto por 2,000 imágenes de resonancia magnética de varios pacientes que presentan tejidos sanos y presencia de tumores. Este sistema tuvo un entrenamiento para aprender a diferenciar las distintas características de cada categoría que presentan las imágenes, los resultados del estudio nos demostraron que el modelo consiguió lograr una precisión del 95.4% y una sensibilidad del 94.7%, lo que nos indica la capacidad que tiene para detectar de manera confiable los tumores cerebrales. El potencial que tiene la inteligencia artificial es óptimo para apoyar a los radiólogos, reduciendo su carga de trabajo y brindar los diagnósticos más rápidos y precisos, a pesar de esto el estudio destacó la necesidad de un mayor volumen de datos para mejorar la generalización del modelo y reducir los posibles errores en su entrenamiento.

[23] En el Perú en las regiones rurales estuvieron en una situación crítica por el motivo de disponibilidad limitada de especialistas de salud y equipos médicos avanzados para el

diagnóstico de enfermedades renales, este problema nos ha llevado al incremento de casos que requieren de intervenciones medicas avanzadas, lo que presenta un desafío para la salud pública. Como solución a este problema se desarrolló un sistema inteligente que usa redes neuronales convolucionales para poder detectar enfermedades renales a partir de las imágenes que nos brindan los análisis de orina, este sistema permitirá a los pacientes tomar y enviar imágenes de muestras de orina desde sus dispositivos móviles, facilitando el diagnostico remoto por los especialistas, para la implementación de este sistema se recopiló un conjunto de datos de 5,000 imágenes de muestras de orina que presentan las diferentes patologías renales, el entrenamiento sirvió para poder identificar las características de estas enfermedades en las imágenes logrando una precisión del 97%, una sensibilidad del 98% y una especificidad del 96%, lo que nos refleja la efectividad en la identificación de casos patológicos y la capacidad de distinguir entre pacientes sanos y enfermos. Esto no solo mejora la precisión del diagnóstico, también amplía la atención medica en áreas de infraestructura limitada, reduciendo la carga de trabajo de los especialistas y aumentando la cobertura de atención.

El cáncer de pulmón se define como un crecimiento descontrolado de las células en los tejidos pulmonares, esto provoca la formación de tumores y nódulos debido a las disfunciones en los mecanismos de división celular. Teniendo en cuenta la capacidad de las células tumorales para invadir a otros tejidos se clasifica en dos tipos principales: benignos, que son nódulos que no invaden a otros órganos y malignos que se pueden infiltrar en los tejidos cercanos y producir metástasis [10]. En este estudio detectar los nódulos de manera temprana es fundamental para identificar indicios de cáncer, especialmente en los tipos de células pequeñas y no pequeñas, estas últimas incluyen adenocarcinoma, carcinoma de células escamosas y carcinoma de células grandes que representa el 80% de los casos [11].

La tomografía computarizada es una de las técnicas no invasivas para el diagnóstico por imagen donde se usan rayos x para poder generar cortes transversales detallados del cuerpo humano [12]. Para el cáncer de pulmón las tomografías computarizadas son fundamentales para poder detectar anomalías como podrían ser los nódulos pulmonares, nos proporciona información crítica sobre la extensión y la localización de esta enfermedad. Este estudio tiene como apoyo las tomografías para el entrenamiento del modelo de inteligencia artificial que puede ser capaz de identificar los nódulos, mejorando la rapidez y precisión del diagnóstico [13].

La inteligencia artificial y el machine learning nos permiten desarrollar sistemas que aprendan y mejoren automáticamente mediante los datos sin requerir una programación explícita [13]. Sobre el contexto de la detección de nódulos pulmonares, se emplean los algoritmos de machine learning, estos analizan las imágenes de tomografía computarizada y reconocen los patrones asociados a la presencia de tumores, esta capacidad que tienen para el análisis automatizado les reduce la carga de trabajo de los especialistas médicos y mejora la precisión del diagnóstico [15].

El deep learning es una de las subáreas del aprendizaje automático que se centra en el uso de redes neuronales profundas para la realización de tareas complejas como la detección de objetos en imágenes [16]. En este estudio se usaron redes neuronales convolucionales para poder analizar las imágenes tomográficas de los pulmones, debido a que estas redes son muy eficaces para poder identificar los patrones complejos en datos visuales [17]. Las redes neuronales convolucionales nos permiten analizar las características espaciales de las imágenes lo que es fundamental para identificar nódulos pulmonares, en este estudio se logró una precisión del 91.89% [18].

El preprocesamiento de imágenes es un paso muy importante para mejorar la calidad de las imágenes previo a su análisis mediante los algoritmos de deep learning, en este estudio se usaron las técnicas como el filtrado gaussiano que sirve para reducir el ruido en las imágenes, lo que nos facilita la identificación de las estructuras pequeñas como pueden ser los nódulos [19]. Además, se usó la técnica de normalización para que los datos de las imágenes sean consistentes y compatibles con la entrada del modelo de red neuronal [20].

Materiales y métodos

Debido al problema que se planteó y la necesidad de poder solucionarlo, la investigación se llevara a cabo de manera aplicada debido a que se usarán las tomografías computarizadas de los pacientes, estas servirán de apoyo para la detección de nódulos pulmonares en el diagnóstico de cáncer de pulmón.

Para comprender la problemática que existe en el área de imágenes del hospital y su relación con el cáncer de pulmón se empleó el método analítico que nos permitió realizar un estudio sobre los problemas que tienen los radiólogos en la detección de nódulos. Además, se usó el método experimental que consiste en el entrenamiento del modelo a partir de las tomografías con el fin de evaluar y mejorar la precisión del diagnóstico y finalmente el método de implementación que nos facilitó el desarrollo de un sistema inteligente capaz de integrarse en el flujo de trabajo del hospital.

En cuanto a la recolección de los datos se empleó técnicas de entrevista y análisis documental estas entrevistas se hicieron a los médicos radiólogos quienes nos aportaron información sobre el diagnóstico de nódulos pulmonares.

La población de este estudio se incluye a los médicos radiólogos que nos aportaron especialmente en poder definir los requerimientos del sistema y por otro lado los pacientes del hospital cuya información se usó para poder entrenar y validar modelo.

Asimismo, para el desarrollo del modelo de machine learning se usó la metodología crisp-dm, debido a su enfoque estructurado y flexible el cual nos permite un proceso iterativo en proyectos de minería de datos y machine learning, esta metodología es muy buena para análisis de datos ya que nos facilita la gestión efectiva en el proceso del desarrollo del sistema inteligente y nos permite adaptarse a los cambios en los requisitos del proyecto conforme se va avanzando. Esta metodología cuenta con seis fases la comprensión del negocio, comprensión de los datos, preparación de los datos, modelado, evaluación e implementación.

En la primera fase que es la comprensión del negocio se identificaron los objetivos principales: apoyar al diagnóstico médico mediante la detección de nódulos pulmonares y proporcionar un sistema que pudiera optimizar el tiempo de análisis para los radiólogos del Hospital Regional de Lambayeque. En la segunda fase se analizó las imágenes tomográficas las cuales contenían información sobre la presencia de nódulos pulmonares, su área, y otros metadatos importantes para la detección. La tercera fase consistió en una serie de procesos de


limpieza y transformación, esenciales para asegurar la calidad de las imágenes que alimentarían al modelo. En la cuarta fase que es el modelado se seleccionó el algoritmo de redes neuronales convolucionales (cnn) se fundamentó en su capacidad de detectar patrones complejos y su aplicación exitosa en tareas de análisis de imágenes médicas. Finalmente, la fase de evaluación que fue realizada sobre el conjunto de validación y prueba para medir su capacidad predictiva. Las métricas utilizadas incluyeron la precisión, sensibilidad y especificidad del modelo. Los resultados mostraron una sensibilidad del 92%, indicando que el modelo tenía una alta capacidad para detectar nódulos presentes en las imágenes.

Para el desarrollo del producto acreditable primero se definieron las interfaces del sistema en un aplicativo web en el cual se usaron el framework flask y tecnologías como html, css y javascript para poder asegurar que el sistema fuera accesible y fácil de usar para los especialistas médicos en el hospital. Además, se hizo un manual de usuario con la finalidad de orientar al personal médico del hospital para que pudiera manejar el sistema con facilidad

El estudio se llevó a cabo en el Hospital Regional de Lambayeque donde se obtuvo la autorización del personal médico y administrativo, en particular en el área de imágenes. Se mantuvo la confidencialidad y la protección de los datos del paciente durante el proceso, para la implementación del sistema se usaron tomografías proporcionadas por el hospital asegurando que su uso fuera ético y respetuoso siguiendo los lineamientos de protección de datos personales. Asimismo, a través de la plataforma turnitin se confirmó que la investigación no supere el 25% lo que nos garantiza la autenticidad de la investigación y el desarrollo del sistema en comparación con otros estudios.

Resultados y discusión

En base a los objetivos de investigación, como primer objetivo se tiene determinar el algoritmo de preprocesamiento de imágenes para la extracción de datos de las tomografías computarizadas, el preprocesamiento es una fase fundamental en el análisis de datos médicos especialmente en el contexto de las tomografías, este proceso incluye varias etapas que nos permiten preparar las imágenes para que el modelo pueda analizarlas de manera precisa. Primero se realiza la lectura de las imágenes dicom, que es el formato estándar en el ámbito de salud para el intercambio de imágenes, para eso usamos la biblioteca pydicom el cual nos permite leer y manipular estos archivos, también nos proporciona accesos a los datos de píxeles y la información de metadatos de las tomografías lo cual es fundamental para aplicar las técnicas de procesamiento, la normalización es una técnica fundamental debido a que nos permite transformar los valores de los píxeles al rango $[0,1]$ esto se logra dividiendo los valores de los píxeles el su valor máximo, este proceso ayuda a mejorar la convergencia del modelo durante el entrenamiento al reducir las variaciones extremas y hacer que el modelo sea menos susceptible a cambios de intensidad en las imágenes. Luego se realiza el redimensionamiento de las imágenes a una resolución 128×128 píxeles lo cual nos facilita el procesamiento y permite que el modelo interprete las características de las imágenes. Además, se realiza un filtro gaussiano para poder reducir el ruido de las imágenes suavizando las áreas donde las variaciones de intensidad son pequeñas lo cual mejora la precisión del modelo.



Como segundo objetivo se planteó determinar el porcentaje de los algoritmos de aprendizaje automático en el diagnóstico de nódulos pulmonares, para cumplir este objetivo se hizo una comparación entre distintos algoritmos y se evaluaron las capacidades para la detección de patrones en imágenes médicas, algunas de las técnicas que se tomaron en cuenta son.

Máquinas de vectores de soporte (svm), son algoritmos supervisados usados para problemas de clasificación, estos se emplean en tareas donde la separación entre clases es lineal o casi lineal, el cual se pueden llegar a buenos resultados siempre y cuando se tenga los datos estructurados y de alta dimensionalidad. Sin embargo, tienen ciertas limitaciones en el procesamiento de imágenes complejas como las tomografías computarizadas, ya que no son capaces de capturar las características espaciales de la imágenes, para poder trabajar con este algoritmo tendríamos que realizar una extracción manual de las características, lo que nos llevaría a una pérdida de información importante, esta pérdida nos afecta negativamente en la precisión del modelo, porque las características podrían no representar de manera precisa la estructura de los nódulos . La segunda técnica son los árboles de decisión y los bosque aleatorios , esta técnica es popular en el machine learning debido a la facilidad de interpretación y su capacidad de poder manejar datos no lineales, pero el desempeño que tiene en la detección de patrones en imágenes medicases limitado, aunque los bosques aleatorios son capaces de manejar grandes conjunto de datos, la capacidad que tienen para aprender las representaciones complejas en las imágenes es inferior a los modelos basados en redes neuronales, similar a svm los árboles de decisión y bosques aleatorios requieren una extracción manual de la características de las imágenes. La tercera técnica k-nearest neighbors(knn), esta algoritmo clasifica los datos en función de la proximidad a los puntos de datos en el conjunto de entrenamiento, aunque es fácil de implementar y funciona bien knn no es adecuado para las tareas complejas de reconocimiento de patrones en las imágenes , porque no tiene la capacidad de aprendizaje explícita y el rendimiento baja mucho en la presencia de datos de alta dimensionalidad como son las imágenes médicas, además knn no capta las relaciones espaciales entre los pixeles una caracteriza fundamental para la detección de los nódulos. Por ultimo las redes neuronales convolucionales(cnn) nos han demostrado que es la mejor opción para procesamiento de imágenes especialmente en poder detectar los patrones complejos y en el análisis de los datos espaciales como las tomografías, la diferencia con respecto a los anteriores , las cnn pueden aprender características directamente de las imágenes , esto lo realiza a través de la capas convolucionales , el modelo puede identificar las características específicas de los nódulos pulmonares como su forma, tamaño y textura, sin la necesidad de hacer una extracción manual de las características, también aprovechan la información espacial de la imágenes el cual nos permite una mayor precisión en la identificación de estructuras complejas en los pulmones. Otra ventaja que tienen es la capacidad de poder manejar grandes volúmenes de datos de imágenes y la flexibilidad para poder ajustar la arquitectura según nuestras necesidades específicas del problema, lo que nos

ayuda en la mejora de la precisión y la sensibilidad del modelo, en el caso de esta investigación se usaron las métricas de precisión, sensibilidad y especificidad para la evaluación del modelo cnn, logrando así buenos resultados. Finalmente, aunque los otros algoritmos nos ofrecen ventajas en ciertos contextos, las cnn nos presentan ventajas claras y específicas para el análisis de imágenes médicas.

En relación con el tercer objetivo, que se refiere a diseñar un modelo computacional para detectar un modelo computacional para detectar los nódulos pulmonares. El modelo de diseño usando una arquitectura de red neuronal convolucional entrenada con imágenes en formato dicom, esta red neuronal incluye capas convolucionales y de pooling, el cual se encarga de extraer las características importantes y nos reducen la dimensión de las representaciones, también se usó la activación relu , en lo que es las capas intermedias para poder facilitar la convergencia durante el entrenamiento y por ultimo un activación sigmoide en la capa de salida para poder clasificar la imagen en presencia o ausencia de nódulos pulmonares.

```
# Define las dimensiones de las imágenes y los canales (dependiendo del formato de color)
img_height = 128 # Altura de la imagen
img_width = 128 # Ancho de la imagen
img_channels = 1 # Número de canales (por ejemplo, 3 para RGB)

# Luego, puedes usar estos valores en la definición de tu modelo CNN
model = Sequential([
    Conv2D(32, (3, 3), activation='relu', input_shape=(img_height, img_width, img_channels)),
    MaxPooling2D((2, 2)),
    Conv2D(64, (3, 3), activation='relu'),
    MaxPooling2D((2, 2)),
    Flatten(),
    Dense(128, activation='relu'),
    Dense(1, activation='sigmoid') # Output layer for binary classification (e.g., nodule or not)
])
```

Para el cuarto objetivo, el cual es validar la precisión del modelo para detectar nódulos pulmonares. Para la validación el cual es una etapa crucial en el modelo en el desarrollo de aplicaciones médicas donde la precisión y la confiabilidad es fundamental para un diagnóstico confiable, consistió en primero la división de conjunto de datos, que fue dividido en tres partes, entrenamiento, validación y prueba. El conjunto de entrenamiento se usó para poder ajustar el modelo, los datos de validación para optimizar los hiperparámetros y poder evitar el sobreajuste, y por último el conjunto de prueba para evaluar el rendimiento final. Segundo, el

entrenamiento y validación, durante es te proceso el modelo se ajustó usando el conjunto de validación para la optimizar los hiperparámetros, tales como la tasa del aprendizaje y el número de épocas, esto nos asegura que el modelo generalice bien y no memorice los datos específicos del entrenamiento. Por último, la evaluación final del modelo, para la evaluación de usa el conjunto de prueba para medir su precisión, se calculó las métricas de precisión, sensibilidad y especificidad logrando así una precisión de 91.89% en la validación.

```
# Evaluar el modelo en el conjunto de validación
loss, accuracy = model.evaluate(X_val_resized, y_val)
print('Pérdida en el conjunto de validación:', loss)
print('Precisión en el conjunto de validación:', accuracy)

2/2 [=====] - 0s 58ms/step - loss: 0.1793 - accuracy: 0.9189
Pérdida en el conjunto de validación: 0.17930355668067932
Precisión en el conjunto de validación: 0.9189189076423645
```

Esto, nos indica un buen rendimiento en la detección de nódulo. Los resultados de la evaluación nos indica que el modelo es confiable y efectivo para la detección de los nódulos en las tomografías.

En la discusión, la implementación de la metodología crisp-dm en el modelo para la detección de nódulos pulmonares se justifica por su eficacia en la estructuración del análisis de datos médicos. Esta metodología ha sido útil en estudios previos como el de la detección de cáncer de mama [7], donde se destaca la importancia de una metodología robusta para la evaluación y desarrollo de algoritmos. En la fase de comprensión del negocio el estudio se centró en el desarrollo de un sistema de apoyo al diagnóstico, similar a lo que se observó en estudios enfocados en optimizar la carga de trabajo de los radiólogos mediante herramientas automatizadas de diagnóstico [8], evidenciando la relevancia de integrar soluciones tecnológicas en entornos hospitalarios.

El preprocesamiento de imágenes con técnicas como la normalización de los valores de píxeles y la aplicación de filtros gaussianos permitió mejorar la calidad de las tomografías y facilitar el análisis automático. Este enfoque es comparable al utilizado en el estudio de melanoma de la piel [9], donde el procesamiento de imágenes fue fundamental para optimizar la precisión de los modelos de deep learning. En ambos casos, el preprocesamiento fue clave para destacar características relevantes, con la diferencia que el presente trabajo se centró en tomografías dicom, mientras que [9] trabajó con imágenes en formato jpg.

El uso de redes neuronales convolucionales para la detección de nódulos pulmonares demostró ser una elección adecuada, alcanzando una precisión del 91.89%, una sensibilidad del 92% y una especificidad del 89%, valores que nos evidencian que hay un equilibrio adecuado entre la detección de nodulos y la reducción de falsos positivos. Esto es consistente con estudios como [22] y [23], que también emplearon redes neuronales para el diagnóstico de enfermedades a partir de imágenes médicas, logrando precisiones similares, estas redes

neuronales destacan por su capacidad de capturar patrones complejos, lo cual se evidenció tanto en la detección de tumores cerebrales como en la identificación de patologías renales. En este estudio, la elección de redes neuronales fue impulsada por la necesidad de identificar características espaciales detalladas de los nódulos, similar a la estrategia adoptada en [8]. Asimismo, el modelo fue entrenado con un conjunto de más de 400 imágenes tomográficas, el cual se dividió en 70% para el entrenamiento, 15% para la validación y 15% para la prueba, esto permitió una evaluación confiable de su capacidad predictiva. La fase de validación, con un enfoque en la precisión, sensibilidad y especificidad, mostró resultados sólidos, reflejando la importancia de un conjunto de datos adecuado y técnicas de preprocesamiento efectivas. En estudios como [7], la implementación de un sistema automatizado de diagnóstico también mejoró significativamente la precisión, facilitando el trabajo de los especialistas. En este caso, el sistema diseñado no solo alcanzó una precisión notable, sino que también demostró ser una herramienta eficiente para el diagnóstico temprano, un aspecto crítico en la reducción de la mortalidad por cáncer de pulmón.

En conclusión, los resultados obtenidos con estudios previos resaltan la efectividad de utilizar redes neuronales y metodologías estructuradas como *crisp-dm* para mejorar el análisis de imágenes médicas. La integración de tecnologías avanzadas ha permitido desarrollar un sistema de apoyo robusto para el diagnóstico, que, al igual que en [21] y [23], busca no solo mejorar la precisión diagnóstica sino también facilitar el acceso a servicios médicos en áreas con recursos limitados.

Conclusiones

La investigación concluyó que el sistema inteligente basado en deep learning fue eficaz para apoyar el diagnóstico de cáncer pulmonar, cumpliendo plenamente con los objetivos planteados. El uso de redes neuronales convolucionales permitió una detección precisa de los nódulos pulmonares, contribuyendo a la automatización del proceso de análisis de imágenes médicas en el Hospital Regional de Lambayeque. Este avance no solo redujo significativamente la carga de trabajo de los radiólogos, sino que también mejoró la precisión y rapidez del diagnóstico, lo que resultó en un beneficio directo para los pacientes al permitir la detección temprana del cáncer y un mejor tratamiento.

Asimismo, se confirmó la viabilidad del uso de técnicas de preprocesamiento, como la normalización y los filtros gaussianos, para optimizar la calidad de las imágenes y aumentar el rendimiento del modelo. La metodología XP aplicada en la investigación demostró ser efectiva para estructurar el proceso de desarrollo del sistema, lo que refuerza la hipótesis de que la inteligencia artificial, específicamente el deep learning, puede integrarse de manera exitosa en entornos médicos para mejorar los diagnósticos y optimizar los recursos disponibles en los hospitales.

Recomendaciones

Se recomienda continuar con la optimización del sistema inteligente mediante el uso de bases de datos más amplias y diversas, lo que permitirá mejorar la precisión y robustez del modelo en diferentes escenarios clínicos. Además, sería beneficioso explorar el uso de otros algoritmos de machine learning o deep learning que complementen las redes neuronales convolucionales para mejorar la detección de nódulos más pequeños o difíciles de identificar, también se sugiere realizar pruebas en otros centros médicos para validar la eficacia del sistema en diferentes entornos hospitalarios y con distintos equipos de tomografía.

Por otro lado, se recomienda la integración del sistema con otras herramientas de diagnóstico médico, como el análisis de datos clínicos y genéticos, para ofrecer una solución integral en la detección y tratamiento del cáncer pulmonar, asimismo es importante considerar la capacitación continua del personal médico en el uso de este tipo de sistemas automatizados, asegurando una adecuada implementación y aprovechamiento de las tecnologías en la práctica clínica diaria y finalmente, se sugiere que futuras investigaciones evalúen el impacto económico de la implementación de este tipo de tecnologías en el sector salud, a fin de medir su costo-beneficio.

Referencias

- [1] "CÁNCER DE PULMÓN. GUÍA PARA PACIENTES Y FAMILIARES". [Gepac](http://www.gepac.es/multimedia/gepac2016/pdf/GUIA_PULMON_GEPAC.pdf). Disponible en: http://www.gepac.es/multimedia/gepac2016/pdf/GUIA_PULMON_GEPAC.pdf. [2] F. Bray, J. Ferlay, I. Soerjomataram, R. Siegel, L. Torre, and A. Jemal, "Global cancer statistics 2020: Globocan estimates of incidence and mortality worldwide for 36 cancers in 185 countries," *CA Cancer Journal for Clinicians*. <https://acsjournals.onlinelibrary.wiley.com/doi/full/10.3322/caac.21660> Clinicians.
- [3] "Las cifras del cáncer en España 2021". SEOM: Sociedad Española de Oncología Médica. https://seom.org/images/Cifras_del_cancer_en_España_2021.pdf.
- [4] "Estadísticas importantes sobre el cáncer de pulmón". American Cancer Society | Information and Resources about for Cancer: Breast, Colon, Lung, Prostate, Skin. <https://www.cancer.org/es/cancer/cancer-de-pulmon/acerca/estadisticas-clave.html#:~:text=Alrededor%20del%2013%%20de%20todos,117,910%20hombres%20y%20118,830%20mujeres>
- [5] "Inteligencia artificial y deep learning: Aliadas de la medicina - [dynatec](https://dynatec.es/2022/01/19/inteligencia-artificial-y-deep-learning-aliadas-de-lamedicina/)". Dynatec. <https://dynatec.es/2022/01/19/inteligencia-artificial-y-deep-learning-aliadas-de-lamedicina/>
- [6] H. M. "Deep learning o aprendizaje profundo: ¿qué es?" Formación en ciencia de datos | DataScientest.com. <https://datascientest.com/es/deep-learning-definicion>
- [7] K. L. Yacolca Huamán, «Estudio de Atipia celular utilizando redes neuronales convolucionales: aplicación en tejidos de cáncer de mama», Tesis de pregrado, Pontificia Universidad Católica del Perú, Lima, 2020. Disponible en: https://tesis.pucp.edu.pe/repositorio/bitstream/handle/20.500.12404/18219/YACOLCA_HUAMAN_KARLA_LUCIA_ESTUDIO_ATIPIA_CELULAR.pdf?sequence=1&isAllowed=y 21
- [8] J. Ramon Cueva. "SISTEMA INTELIGENTE PARA APOYAR AL ANÁLISIS MAMOGRAFICO EN LA DETECCIÓN DE TUMORES DE MAMA FEMENINO ENTRE LAS EDADES DE 40 A 60 AÑOS EN EL HOSPITAL "LAS MERCEDES" DE CHICLAYO". https://tesis.usat.edu.pe/bitstream/20.500.12423/4067/1/TL_RamonCuevaJose.pdf [9] C. Pérez Lorenzo, «Detección precoz de cáncer de piel en imágenes basado en redes convolucionales», Tesis de grado, Universidad Autónoma de Madrid, Madrid, Spain, 2019.

https://repositorio.uam.es/bitstream/handle/10486/688935/perez_lorenzo_cristina_tfg.pdf?sequence=1

- [10] W. D. Travis et al., WHO Classification of Tumours of the Lung, Pleura, Thymus and Heart, 4th ed., Lyon, France: IARC Press, 2015.
- [11] American Cancer Society, "Types of Non-Small Cell Lung Cancer," 2021. [Online]. Available: <https://www.cancer.org/>
- [12] E. J. Hall and A. J. Giaccia, Radiobiology for the Radiologist, 7th ed., Philadelphia: Lippincott Williams & Wilkins, 2012.
- [13] F. Ma et al., "Deep Learning-Based Image Reconstruction and Analysis in Medical Imaging," *IEEE Trans. Med. Imaging*, vol. 39, no. 4, pp. 917-929, Apr. 2020.
- [14] T. M. Mitchell, Machine Learning, New York: McGraw-Hill, 1997.
- [15] I. Goodfellow, Y. Bengio, and A. Courville, Deep Learning, Cambridge: MIT Press, 2016.
- [16] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," in *Proc. NIPS*, 2012.
- [17] D. Shen, G. Wu, and H. I. Suk, "Deep Learning in Medical Image Analysis," Annu. Rev. Biomed. Eng., vol. 19, pp. 221-248, 2017.
- [18] J. Liu et al., "Automated Detection of Pulmonary Nodules Using 3D Deep Convolutional Neural Networks," *IEEE Trans. Med. Imaging*, vol. 39, no. 2, pp. 362-372, Feb. 2020.
- [19] R. C. Gonzalez and R. E. Woods, Digital Image Processing, 4th ed., New York: Pearson, 2018.
- [20] S. Marschner and P. Shirley, Fundamentals of Computer Graphics, 4th ed., Boca Raton: CRC Press, 2016.
- [21] A. Catalan, "Técnicas de procesamiento digital de imágenes | Revista de Marina". Home | Revista de Marina. <https://revistamarina.cl/es/articulo/tecnicas-de-procesamiento-digital-de-imagenes>
- [22] M. Aamir et al., "A Deep Analysis of Brain Tumor Detection from MR Images Using Deep Learning Networks," *Journal of Imaging*, vol. 9, no. 2, pp. 103-112, 2022. [Online]. Available: <https://www.mdpi.com/journal/jimaging>.
- [23] A. Khalil et al., "Modified Two-Step Dragonfly Algorithm for Brain Tumor Segmentation Using 3D MR Images," *IEEE Access*, vol. 10, pp. 47354-47365, 2022.

Anexos

ANEXO N° 01. CONSTANCIA DE APROBACIÓN DEL PRODUCTO ACREDITABLE DE LA ENTIDAD DONDE SE EJECUTÓ LA TESIS



HOSPITAL REGIONAL LAMBAYEQUE
SERVICIO DE IMAGENOLOGIA
¡La más alta tecnología al alcance de todos!



Chiclayo, 10 de octubre del 2024

Dra. Jenny Paola Cisneros Tenorio

ASUNTO: CONSTANCIA DE APROBACIÓN DEL PRODUCTO ACREDITABLE

TRABAJO DE INVESTIGACIÓN:

SISTEMA INTELIGENTE BASADO EN DEEP LEARNING PARA EL APOYO EN EL DIAGNÓSTICO DE CÁNCER PULMONAR EN EL HOSPITAL REGIONAL DE LAMBAYEQUE

De mi consideración:

Quien suscribe, y en mi calidad de jefa del departamento de apoyo al diagnóstico, es grato dirigirme a usted con la finalidad de saludarlo cordialmente, asimismo, mediante la presente se suscribe que, habiendo revisado exhaustivamente el producto acreditable de la tesis titulada "SISTEMA INTELIGENTE BASADO EN DEEP LEARNING PARA EL APOYO EN EL DIAGNÓSTICO DE CÁNCER DE PULMONAR EN EL HOSPITAL REGIONAL DE LAMBAYEQUE", presentado por el estudiante TORRES SANCHEZ ANDY ALBERTO, con DNI 73105669, identificado con código universitario 172CV72942 de la escuela de Ingeniería de sistemas y computación de la Universidad Católica Santo Toribio de Mogrovejo, se certifica que se ha culminado exitosamente la realización del sistema inteligente, cumpliéndose con el total de los requerimientos establecidos y habiéndose dado las facilidades y apoyo correspondiente en acceder a la información necesaria para el desarrollo de la investigación.

Sin otro particular, me despido de usted.

Atentamente

GOBIERNO REGIONAL LAMBAYEQUE
 GERENCIA REGIONAL DE SALUD
 HOSPITAL REGIONAL LAMBAYEQUE

 Dra. JENNY PAOLA CISNEROS TENORIO
 E.M.F. 50732 / INE. 04023
 JEFA DEL DPTO. APOYO AL DIAGNÓSTICO

Pro. Augusto B. Lemas N° 100 (IIsq. «a Av. Pro N° 110- 120) - Chiclayo- Chidayo • Lambamos
 Id: (074) 40007
 IMPV/B050001kmbeahrea910.1~7~0b-Pe

ANEXO 02 INTERFACES DEL SISTEMA

MENU PRINCIPAL: Ofrece un acceso rápido a las funciones principales del sistema, incluyendo gestión de pacientes, carga de imágenes DICOM y generación de reportes.



Hospital Regional de Lambayeque

- Inicio
- Registrar Paciente
- Listado de Pacientes
- Realizar Diagnóstico
- Historial de Pacientes
- Reportes
- Cerrar Sesión

Bienvenido al Hospital Regional de Lambayeque



Presentación

El Hospital Regional Lambayeque, es una de las instituciones de mayor importancia y complejidad de la Región Lambayeque, tanto que constituye un Hospital con nivel III-1, es decir nosocomio de ALTA COMPLEJIDAD.


Misión

Somos el Hospital Regional Lambayeque de alta complejidad que brinda servicios integrales de salud, con calidad, equidad y eficiencia, con personal calificado, competente y comprometido, desarrollando Investigación y Docencia, contribuyendo a mejorar la calidad de vida de las personas.

Visión

Ser al 2025 un hospital docente y de investigación, líder, competitivo y reconocido a nivel nacional e internacional, que satisface las necesidades de salud de las personas.

REGISTRAR PACIENTE: Permite hacer el registro del paciente



Hospital Regional de Lambayeque

- Inicio
- Registrar Paciente
- Listado de Pacientes
- Realizar Diagnóstico
- Historial de Pacientes
- Reportes
- Cerrar Sesión

Registro de Pacientes

Nombre

Apellido

Fecha de Nacimiento

Género

Comorbilidades

Otra Comorbilidad (Especifique)

[Registrar](#)

LISTADO DE PACIENTES: Una sección donde se muestra la lista de todos los pacientes incluyendo botones de editar eliminar y en caso de subir imágenes.




Hospital Regional de Lambayeque

- Inicio
- Registrar Paciente
- Listado de Pacientes
- Realizar Diagnóstico
- Historial de Pacientes
- Reportes
- Cerrar Sesión

Listado de Pacientes

Nombre	Apellido	Fecha de Nacimiento	Género	Comorbilidades	Acciones
Bertila	Becerra Cubas	1974-12-30	femenino	Diabetes	Editar Eliminar Subir Imágenes
Maria Elena	Vasquez Zena	1989-10-06	femenino	Diabetes, Hipertensión	Editar Eliminar Subir Imágenes
Maria Esther	Montoya Montalvo	1986-11-27	femenino	Enfermedad cardíaca	Editar Eliminar Subir Imágenes
Yolanda	Aguilar Vela	1963-02-18	femenino	Asma	Editar Eliminar Subir Imágenes

REALIZAR DIAGNÓSTICO: Una interfaz donde se realiza la predicción sobre las tomografías.



Hospital Regional de Lambayeque

- Inicio
- Registrar Paciente
- Listado de Pacientes
- Realizar Diagnóstico
- Historial de Pacientes
- Reportes
- Cerrar Sesión


Realizar Diagnóstico

Seleccione el Paciente

Seleccionar archivos DICOM

 Ningún archivo seleccionado

RESULTADOS MULTIPLES: El sistema usará el modelo de CNN para procesar las imágenes y detectar la presencia de nódulos.



Hospital Regional de Lambayeque

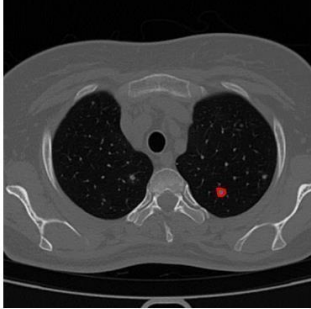
- Inicio
- Registrar Paciente
- Listado de Pacientes
- Realizar Diagnóstico
- Historial de Pacientes
- Reportes
- Cerrar Sesión

Resultados Múltiples

Paciente: Bertila Becerra Cubas

Archivo: U0000052.dcm
Predicción: **Nódulo (Confianza: 0.87)**

Predicción: Nódulo (Confianza: 0.87) - U0000052.dcm




[Descargar](#)

Archivo: U0000053.dcm
Predicción: **Nódulo (Confianza: 0.86)**

Predicción: Nódulo (Confianza: 0.86) - U0000053.dcm

HISTORIAL DE PACIENTES: Una interfaz donde se visualiza los detalles del paciente como datos, comorbilidades y predicciones.



Hospital Regional de Lambayeque

- Inicio
- Registrar Paciente
- Listado de Pacientes
- Realizar Diagnóstico
- Historial de Pacientes
- Reportes
- Cerrar Sesión

Historial de Pacientes

Bertila Becerra Cubas

Maria Elena Vasquez Zena

Maria Esther Montoya Montalvo

Nombre: Maria Esther

Apellido: Montoya Montalvo

Fecha de Nacimiento: 1986-11-27

Género: femenino

Comorbilidades:

- Enfermedad cardíaca

Predicciones:

- U0000045.dcm - Nódulo (Confianza: 0.8234575390815735) [Ver Imagen](#)
- U0000046.dcm - Nódulo (Confianza: 0.8096791505813599) [Ver Imagen](#)
- U0000048.dcm - No Nódulo (Confianza: 0.8334261476993561) [Ver Imagen](#)
- U0000047.dcm - Nódulo (Confianza: 0.6187350749969482) [Ver Imagen](#)
- U0000049.dcm - No Nódulo (Confianza: 0.9474914222955704) [Ver Imagen](#)
- U0000044.dcm - Nódulo (Confianza: 0.8033170700073242) [Ver Imagen](#)

[Editar](#)
[Eliminar](#)
[Ver Reporte Completo](#)