



**PROYECTO DE GRADO**

**AI-BONE X: APLICATIVO DE INTELIGENCIA ARTIFICIAL APOYADO  
EN EL MODELO CONVOLUCIONAL PARA EL DIAGNÓSTICO DE  
FRACTURAS EN EL CONTEXTO CLÍNICO DE LA CIUDAD DE  
VALLEDUPAR**

**DIRECTOR:**

TONNY JIMÉNEZ MÁRQUEZ

**INTEGRANTES:**

WISTON ALBERTO BAUTE BAUTISTA

CC1003316745

**[wbaute@unicesar.edu.co](mailto:wbaute@unicesar.edu.co)**

JUAN DAVID AYALA PRIMO

CC106583443

**[jdayala@unicesar.edu.co](mailto:jdayala@unicesar.edu.co)**

**2025**

## TABLA DE CONTENIDO

	<b>Pág.</b>
<b>Sección I: Descripción General</b>	<b>1</b>
<b>Sección II. Descripción Situacional</b>	<b>3</b>
<b>Sección III. Desarrollo Científico-Tecnológico</b>	<b>23</b>
<b>Sección IV. Artículo Científico</b>	<b>57</b>
<b>Anexos</b>	<b>75</b>

## **ESQUEMA DEL ANTEPROYECTO DE GRADO**

### **PRELIMINARES**

#### **SECCIÓN I: Descripción General**

- 1.1 Título del Proyecto de Grado
- 1.2 Dirección de Ejecución
- 1.3 Lapso de Ejecución
- 1.4 Organismo o Institución Responsable del Proyecto
- 1.5 Información de contacto de los estudiantes
- 1.6 Línea, sub-línea y grupo de investigación del Proyecto

#### **SECCIÓN II: Descripción Situacional**

- 2.1 Identificación del Problema
- 2.2 Justificación del Proyecto
- 2.3 Objetivos del Proyecto
- 2.4 Bases Teóricas
  - 2.4.1 Antecedentes
    - 2.4.1.1 Antecedentes históricos.
    - 2.4.1.2 Antecedentes investigativos.
    - 2.4.1.3 Antecedentes legales.
  - 2.4.2 Marco Teórico
  - 2.4.3 Marco Conceptual
- 2.5 Marco Metodológico

### **SECCIÓN III : Desarrollo Científico-Tecnológico**

3.1 Desarrollo de las fases de la metodología de sistemas propuesta

3.2 Análisis de Resultados y Discusión

3.3 Conclusiones

3.4 Recomendaciones

3.5 Bibliografía

### **SECCIÓN IV: Artículo Científico**

#### **Anexos**

Anexo **A**. Carta del director, Co director, Asesor

Anexo **B**. Carta de los estudiantes

Anexo **C**. Carta recibido a satisfacción de la entidad responsable

Anexo **D**. Artículo científico (cuando aplique)

Anexo **E**. Manual de usuario y manual técnico (Si aplica)

Anexo **F**. Resultado de revisión que evidencie una tolerancia máxima de 25% de no originalidad.

## SECCIÓN I: DESCRIPCIÓN GENERAL

### 1.1.- TÍTULO DEL PROYECTO

AI-BONE X: APLICATIVO DE INTELIGENCIA ARTIFICIAL APOYADO EN EL MODELO CONVOLUCIONAL PARA EL DIAGNÓSTICO DE FRACTURAS EN EL CONTEXTO CLÍNICO DE LA CIUDAD DE VALLEDUPAR

### 1.2.- DIRECCIÓN DE EJECUCIÓN DEL PROYECTO

La aclaración del lugar de ejecución se encuentre en el (ANEXO C)

### 1.3.- LAPSO DE EJECUCIÓN DEL PROYECTO

6 meses de duración

Del 12 de agosto del 2024 al 12 de enero de 2025

### 1.4.- ORGANISMO Y SECCIÓN RESPONSABLE

El proyecto final de IA para la detección de fracturas permitirá contar con un prototipo experimental que estará disponible para cualquier entidad del sector salud en el contexto clínico de la ciudad de Valledupar (ANEXO C, C1 Y C2)

### 1.5.- INFORMACIÓN DE CONTACTO DE LOS ESTUDIANTES

Nombre	Apellido	Cédula	Teléfono	Correo
WISTON	BAUTE	1003316745	3022169464	wbaute@unicesar.edu.co
ALBERTO	BAUTISTA			

<b>Nombre</b>	<b>Apellido</b>	<b>Cédula</b>	<b>Teléfono</b>	<b>Correo</b>
JUAN DAVID	AYALA PRIMO	1065834443	3113964407	jdayala@unicesar.edu.co

**1.6.- LÍNEA, SUBLÍNEA Y GRUPO DE INVESTIGACIÓN AL QUE SE SUSCRIBE EL PROYECTO**

<b>Línea de Investigación</b>	Transformación Digital
<b>Sub-línea de Investigación</b>	Inteligencia Artificial
<b>Área Temática</b>	Redes Neuronales Convolucionales en la medicina
<b>Grupo de Investigación</b>	GISICO

## SECCIÓN II. DESCRIPCIÓN SITUACIONAL

### 2.1.- IDENTIFICACIÓN DEL PROBLEMA

Actualmente, en Colombia se presentan elevadas cifras de accidentes que involucran vehículos automotores, según los datos suministrados por el Instituto Nacional de Medicina Legal y Ciencias Forenses, a través de su informe más actualizado de su revista *Forensis*, se evidencia una alta tasa de muertes y lesiones en el periodo comprendido entre 2016 y 2023 con tendencia al crecimiento, estas estadísticas reflejan una problemática constante y de gran impacto social. [13]

De acuerdo con la revista *Forensis* en su versión del 2023 (citando el mismo estudio con fecha 2016), ubica al Cesar como uno de los departamentos con más muertes y heridos por accidentes en vehículos, esto representa un desafío que enfrentan los servicios de urgencias en Valledupar como lo es la saturación de servicios diagnósticos radiológicos generada por la alta accidentalidad, problema este que va de la mano con la imprudencia vial y el incremento de vehículos que transitan en la ciudad. [12]

De lo anterior nace la necesidad de crear una solución automatizada y que sea eficiente para asistir en la interpretación de imágenes de rayos x, especialmente en áreas como urgencias donde los especialistas no están disponibles todo el tiempo, facilitando así la labor de los médicos generales en el momento del triage.

La innovación tecnológica en el campo de la tecnología médica va de la mano con nuevas máquinas que usan la inteligencia artificial como pilar fundamental ya que brinda como beneficio mejorar la calidad y la uniformidad de la imagen acelerando la recuperación o el diagnóstico previo de alguna enfermedad. [10]

En este contexto, la inteligencia artificial (IA) y en particular los modelos convolucionales de redes neuronales (CNN) han demostrado ser herramientas eficaces para el análisis de imágenes médicas como lo son las imágenes de rayos X para detectar la presencia de fracturas.

La equivalencia entre las CNN y los cerebros biológicos puede comprenderse de forma provechosa en el contexto de los resultados conductuales que producen, más allá de la precisión general en la clasificación de imágenes, para la cual la red ha sido optimizada explícitamente. Las CNN entrenadas para el reconocimiento de objetos genéricos desarrollan representaciones y similitud categórica que se relacionan estrechamente con la forma perceptual humana y los juicios semánticos. [3]

### **FORMULACION DEL PROBLEMA:**

La creciente demanda en los centros médicos por accidentes de tránsito en vehículos ha generado la necesidad de agilizar y optimizar la evaluación de imágenes radiológicas para la detección oportuna de fracturas, mucho de los médicos generales enfrentan limitaciones de tiempo para revisar grandes volúmenes de radiografías y no siempre está disponible un especialista para dar un diagnóstico, lo que afecta la atención inmediata de los pacientes.

Ante esta situación surge la necesidad de desarrollar un aplicativo basado en inteligencia artificial que apoye a los médicos generales en el proceso de triage, especialmente en la interpretación de imágenes de rayos x con sospecha de fractura

En este proyecto se plantea entonces la siguiente pregunta de investigación:

### **Pregunta Principal:**

¿Cómo desarrollar un sistema automatizado basado en inteligencia artificial que permita detectar de manera oportuna y precisa fracturas en imágenes de rayos X, apoyando a los médicos generales en el proceso de triage en centros médicos?

## **Sub-Preguntas:**

¿Qué tipo de arquitectura de red neuronal convolucional resulta más adecuada para el análisis automático de imágenes de rayos x en la detección de fracturas?

¿Cómo integrar herramientas como Python, TensorFlow y OpenCV para construir un sistema eficiente y flexible para la detección de fracturas?

¿Qué estrategias de entrenamiento y validación de datos deben aplicarse para garantizar la precisión y confiabilidad del modelo de IA en diferentes condiciones médicas?

¿Cómo evaluar el impacto del sistema propuesto en la reducción de tiempos de diagnóstico y en el apoyo a médicos no especialistas en escenarios de alta demanda?

La respuesta a estas preguntas permitirá desarrollar, implementar y validar el aplicativo desarrollado en este proyecto.

## 2.2.- JUSTIFICACIÓN DEL PROYECTO

El desarrollo de una aplicación integrada con inteligencia artificial basado redes neuronales convolucionales se ve respaldado por la creciente demanda de incorporar tecnologías avanzadas en el campo de la salud con el fin de mejorar la precisión y eficacia en los diagnósticos médicos, las fracturas son condiciones clínicas comunes que pueden llevar a complicaciones graves si no se detectan a tiempo, aumentando los gastos médicos y teniendo un impacto negativo en la calidad de vida de los pacientes. El objetivo de este proyecto es brindar una herramienta innovadora para ayudar al personal médico en la evaluación automática de imágenes radiológicas, empleando marcos y bibliotecas robustas de Python.

La justificación se fundamenta en diversos aspectos, como lo son la integración de la inteligencia artificial en los procedimientos clínicos que ayuda a disminuir los errores humanos, también mejora la precisión en la identificación de anomalías; Además, agiliza los plazos de diagnóstico en situaciones de gran presión médica en áreas urbanas como Valledupar o áreas rurales del departamento del Cesar, en donde muchos de los centros médicos cuentan con recursos muy limitados; Así mismo, la aplicación está diseñada para ser de escritorio, lo que permite usarse en centros médicos que no tengan conexión a internet, todo esto se logró gracias a uso de herramientas accesibles y de código abierto para conseguir que la solución sea económicamente viable y adaptable a entornos similares, fomentando una equidad tecnológica en el ámbito de la salud.

Además, los cambios tecnológicos en el entorno laboral tienen una larga historia, pero la reciente prioridad en la generación de datos como parte central de la economía digital conlleva transformaciones particulares que merecen mayor atención. [2]

Este proyecto no solamente está aportando a la modernización de los procesos médicos, sino que también promueve la adopción de tecnologías innovadoras como las redes neuronales en aplicaciones prácticas que inciden directamente en la sociedad. De esta manera, se fomenta un enfoque completo para mejorar la calidad de los servicios de salud, lo que resulta beneficioso tanto para los pacientes como para los profesionales médicos.

De la misma manera, cabe aclarar que gracias al artículo científico publicado de la revista "Computerized Medical Imaging and Graphics (Vol. 78)" demostró que Resnet50 comparada con las demás como (AlexNet, Vgg-16, Resnet-18 y Resnet-34) obtuvo mejores resultados en el ámbito de la medicina para el análisis de imágenes y detección de anomalías en resonancias magnéticas y similares como lo son las de rayos x. [14]

En radiología, la IA aprovecha el aprendizaje automático y las técnicas de aprendizaje profundo para analizar grandes volúmenes de imágenes médicas de forma rápida y precisa. Los sistemas de inteligencia artificial, como las redes neuronales profundas, han demostrado su capacidad no solo para ayudar a los radiólogos en la interpretación de imágenes, también para identificar anomalías sutiles, predecir la progresión de la enfermedad y mejorar la precisión del diagnóstico general. Pueden trabajar en conjunto con los radiólogos, funcionando como "segunda opinión" y ayudando a reducir las posibilidades de diagnósticos erróneos. [7]

Para finalizar, se debe aclarar que la sospecha de fracturas es uno de los motivos de consulta más comunes en la atención de urgencias y el uso de la radiografía es la herramienta de diagnóstico más importante, regularmente se encuentra con la situación en urgencias que el médico encargado de turno carece de experiencia en traumatología o en interpretación de radiografías, es por ello por lo que se ha utilizado la inteligencia artificial como apoyo al diagnóstico, en concreto de las fracturas de mano, codo y hombro.[9]

## **2.3.- OBJETIVOS DEL PROYECTO**

### **2.3.1 OBJETIVO GENERAL**

Desarrollar y validar un aplicativo de inteligencia artificial basado en redes neuronales convolucionales (CNN) para asistir en el diagnóstico automatizado de fracturas óseas a partir de imágenes de rayos X de mano, codo y hombro en instituciones clínicas de la ciudad de Valledupar.

### **2.3.2 OBJETIVOS ESPECIFICOS**

- ✓ Analizar un conjunto de datos ajustados a las necesidades de la red neuronal.
- ✓ Preprocesar el conjunto de imágenes médicas por resolución, normalización y aumentación de datos por código que serán utilizadas para entrenar el modelo de la red neuronal convolucional
- ✓ Desarrollar el aplicativo de inteligencia artificial que integre el modelo de red neuronal convolucional para la detección de fracturas por parte de personal médico hasta lograr un estándar de precisión óptimo (Mayor al 70% de precisión basado en las métricas).
- ✓ Validar con datos clínicos el aplicativo de inteligencia artificial apoyado en el modelo de red neuronal convolucional con datos clínicos, evaluando la precisión, rendimiento y el tiempo de respuesta del diagnóstico mediante las métricas de modelo accuracy y matriz de confusión.
- ✓ Presentar un prototipo funcional, verificado por personal médico, que integre el modelo entrenado y permita cargar imágenes para su análisis automático.

## **2.4.- BASES TEÓRICAS.**

### **2. 4.1 ANTECEDENTES**

#### **2.4.1.1. Antecedentes históricos.**

La inteligencia artificial (IA) ha recorrido un largo camino desde sus inicios en la década de 1950. En 1956, la conferencia de Dartmouth, organizada por John McCarthy, Marvin Minsky, Nathaniel Rochester y Claude Shannon, marcó el nacimiento formal de la IA como disciplina académica. Durante este evento, se acuñó el término "inteligencia artificial" y se establecieron las bases para su estudio sistemático; este evento ha sido referido como "la Convención Constitucional de la IA". [16]

En 1966, Joseph Weizenbaum desarrolló ELIZA, el primer chatbot, en el Instituto de Tecnología de Massachusetts (MIT). ELIZA utilizaba procesamiento de lenguaje natural para simular una conversación humana, marcando un hito en la interacción entre humanos y máquinas. [17]

En 1982, John Hopfield propuso la red neuronal conocida como "red de Hopfield", basada en principios físicos como la energía de sistemas de espín, que permite el reconocimiento y reconstrucción de patrones desde datos incompletos. Esta contribución, junto con los avances en redes neuronales profundas, ha sido fundamental para el desarrollo del aprendizaje automático moderno. [18]

En 2024, John Hopfield y Geoffrey Hinton recibieron el Premio Nobel de Física por sus contribuciones fundamentales al desarrollo de redes neuronales artificiales que imitan las funciones del cerebro humano y habilitan el aprendizaje automático. Su investigación, iniciada en la década de 1980, sentó las bases para aplicaciones modernas de la IA, como la traducción de idiomas, el reconocimiento facial y los chatbots [19]

#### 2.4.1.2. Antecedentes investigativos.

Las redes CNN se han visto en diferentes aplicaciones que apoyan su uso en la radiología es el estudio hecho por el doctor Dah Ching Ding en donde se propuso un esquema de identificación automática de tumores ováricos mediante una red neuronal convolucional de conjunto, esto junto con imágenes de ultrasonido, se realizaron diez pruebas de entrenamiento de tres modelos CNN conocidos (Alexnet, GoogleNet, ResNet) para el aprendizaje por transferencia mediante la metodología de aprendizaje profundo, se repitió el muestreo aleatorio de los datos de entrenamiento y validación diez veces para garantizar la estabilidad y robustez del método, los datos de la evaluación final se seleccionaron como la media de los diez resultados de las pruebas. Tras el entrenamiento, se utilizó el aprendizaje de conjunto con respecto a los tres modelos, con una relación de precisión de cálculo respecto al tiempo de clasificación.[4]

Por otro lado, al integrar el aprendizaje automático y el análisis de imágenes, la IA puede colaborar con los radiólogos y médicos, mejorando la eficiencia y la precisión en la detección de fracturas. Según diversos estudios, una segunda opinión puede reducir considerablemente el riesgo de diagnóstico erróneo; esta segunda opinión puede ser dada por una IA y obtener muy buenos resultados. Un estudio donde se llega a esta conclusión es "Automatic hip fracture identification and functional subclassification with deep learning" de Krogue, et al. [8]. Este artículo presenta un sistema basado en aprendizaje profundo para identificar y clasificar automáticamente fracturas de cadera en imágenes médicas. [6]

De la misma manera, el estudio realizado por **Lindsey et al. (2018)**, publicado en la revista *Proceedings of the National Academy of Sciences of the United States of America*, se desarrolló y evaluó una red neuronal profunda para mejorar la detección de fracturas óseas en radiografías, el modelo de inteligencia artificial fue entrenado con miles de imágenes médicas anotadas por especialistas y posteriormente probado junto con la participación de clínicos en la interpretación de radiografías. [15]

Los resultados demostraron que la incorporación de la red neuronal aumentó significativamente la precisión diagnóstica de los profesionales, reduciendo los errores de detección y mejorando la sensibilidad frente a fracturas sutiles que comúnmente pasan desapercibidas en evaluaciones manuales; este trabajo evidenció el potencial del aprendizaje profundo como herramienta de apoyo al diagnóstico médico, contribuyendo a optimizar los tiempos de revisión, la eficiencia clínica y la calidad del diagnóstico radiológico, de esta manera, el estudio constituye un referente clave en la aplicación de modelos de redes neuronales profundas dentro del campo de la radiología, sirviendo como base para investigaciones orientadas a la detección automática de fracturas mediante imágenes médicas. [15]

#### **2.4.1.3. Antecedentes legales.**

En el ámbito legal, el uso de la inteligencia artificial en la medicina está regulado por diversas normativas que buscan garantizar la seguridad y privacidad de los pacientes, así como la validez de los diagnósticos. En Colombia, el **Ministerio de Salud y Protección Social** establece normativas para la implementación de tecnologías en el área de la salud, destacando la **Ley Estatutaria 1751 de 2015** sobre el derecho a la salud, la cual establece principios como la **protección de datos personales** en el contexto de la salud de los pacientes.

A nivel internacional, la **Reglamento General de Protección de Datos (GDPR)** en Europa regula el uso de datos personales en todos los sectores, incluida la salud. Estas normativas exigen que los modelos de IA en medicina cumplan con estrictos criterios de **transparencia y privacidad**. Además, organismos como la **FDA (Food and Drug Administration)** en EE. UU. han comenzado a regular dispositivos médicos basados en IA, asegurando que los sistemas utilizados para el diagnóstico sean precisos y confiables.

## 2.4.2 MARCO TEÓRICO

En este marco, se exploran los principios teóricos que fundamentan el uso de la inteligencia artificial, en particular el uso de redes neuronales convolucionales (CNN) para la clasificación de imágenes médicas. Las CNN son un tipo de modelo de aprendizaje profundo que se destacan por su capacidad para aprender representaciones jerárquicas de las imágenes, estos modelos son ampliamente utilizados en tareas de visión por computadora, como la detección de fracturas, gracias a su habilidad para identificar patrones complejos en datos visuales. [20]

La teoría subyacente a las CNN se basa en las operaciones convolucionales, que permiten la detección de características locales como bordes, texturas y formas dentro de una imagen, este tipo de redes ha sido probado con éxito en una variedad de aplicaciones médicas, incluyendo la clasificación de tumores, la segmentación de tejidos y la identificación de fracturas óseas en radiografías. [21]

El desarrollo de sistemas de detección mediante CNN se ha consolidado como una de las áreas más prometedoras en inteligencia artificial y visión por computadora debido a su capacidad para extraer y aprender características complejas de datos visuales, las CNN han demostrado un alto rendimiento en tareas de clasificación y segmentación de imágenes, lo que las convierte en una herramienta eficaz para aplicaciones médicas como la detección de fracturas y neumonías a partir de radiografías, permitiendo analizar automáticamente imágenes diagnósticas y reduciendo la dependencia exclusiva de la interpretación humana.[22]

En este contexto, Python se ha convertido en el lenguaje de programación de referencia para la implementación de modelos de aprendizaje profundo, gracias a su sintaxis clara, su amplia comunidad de desarrolladores y la disponibilidad de bibliotecas especializadas como TensorFlow, Keras y PyTorch; que facilitan el preprocesamiento de imágenes, la construcción de arquitecturas de redes neuronales y el entrenamiento supervisado de modelos, optimizando así tanto el tiempo de desarrollo como la precisión de los resultados.

El uso de CNN para diagnóstico médico no solo se fundamenta en la capacidad de identificar patrones visuales complejos, sino también en su adaptabilidad para aprender de grandes volúmenes de datos etiquetados. Este aprendizaje permite mejorar la capacidad predictiva del modelo a medida que se amplía el conjunto de datos, lo que resulta esencial en entornos donde la variabilidad de las imágenes médicas es alta. Además, la integración de estas tecnologías en los sistemas de salud plantea beneficios como la detección temprana de enfermedades, la reducción de errores humanos y la optimización de los recursos hospitalarios, contribuyendo así a una atención más precisa y eficiente.

### 2.4.3 MARCO CONCEPTUAL

En este marco, se definen los conceptos clave utilizados en este proyecto:

- **Inteligencia Artificial (IA):** Campo de la informática que simula procesos de inteligencia humana a través de algoritmos y modelos matemáticos. En este caso, se utiliza para el diagnóstico médico mediante el análisis de imágenes.
- **Triage:** Es un sistema de selección y clasificación de pacientes en los servicios de urgencia, basado en sus necesidades terapéuticas y los recursos disponibles para atenderlo.
- **Iteración O Epoca:** Iteración significa repetir varias veces un proceso con la intención de alcanzar una meta deseada, objetivo o resultado.
- **Redes Neuronales Convolucionales (CNN):** Tipo de red neuronal diseñada para procesar datos visuales, especialmente utilizada en visión por computadora para tareas de clasificación y detección de objetos.
- **Diagnóstico de fracturas:** Proceso médico que implica la identificación de fracturas óseas a partir de imágenes, como radiografías, tomografías computarizadas o resonancias magnéticas.
- **Dataset:** Sistema donde la información se almacena en una estructura de directorios y carpetas, donde existen relaciones entre ellas para facilitar la organización, búsqueda y acceso a los datos.
- **Anonimización:** es el proceso de eliminar o modificar datos personales identificables para que no puedan asociarse con una persona en particular.

- **Diagnóstico de fracturas:** Proceso médico que implica la identificación de fracturas óseas a partir de imágenes, como radiografías, tomografías computarizadas o resonancias magnéticas.
- **Deep Learning (Aprendizaje Profundo):** Subcampo del aprendizaje automático que utiliza redes neuronales con múltiples capas para aprender representaciones de datos complejos.
- **Machine Learning:** Disciplina del campo de la Inteligencia Artificial que, a través de algoritmos, dota a los ordenadores de la capacidad de identificar patrones en datos grandes y elaborar predicciones.
- **TensorFlow:** Biblioteca open source (Código Abierto) desarrollada por Google para llevar a cabo tareas de Machine Learning y Deep Learning.
- **Clasificación de Imágenes:** Proceso mediante el cual se asigna una etiqueta o categoría a una imagen en función de su contenido visual.
- **Evaluación del Modelo:** Se refiere a la medición del rendimiento del modelo desarrollado utilizando métricas como la precisión, sensibilidad, especificidad y el tiempo de respuesta.

## 2.5 MARCO METODOLÓGICO

### Métodos y Técnicas de Recolección e Interpretación de la Información

- **Desarrollo experimental:** Se diseñará y entrenará una red neuronal convolucional, para integrarla en el aplicativo basado en el modelo convolucional CNN y ResNet50.

Se debe saber que una CNN se forma apilando las capas de entrada, convolución, agrupación, completamente conectada y salida, la capa de entrada es la primera capa de una CNN, la entrada a una CNN consiste en imágenes sin procesar, que son vectores bidimensionales o tridimensionales, luego está la capa convolucional, que es el núcleo de una CNN, generalmente consiste en un conjunto de filtros o núcleos aprendibles con pequeños campos perceptuales. [8]

Por otra parte, ResNet 50 como una red convolucional especializada es entrenada con el conjunto de datos del proyecto y se modifican las últimas capas (lo que se denomina reentrenamiento o aprendizaje por transferencia), se utiliza para lograr resultados óptimos, este es el mejor enfoque para empezar, en lugar de intentar inventar nuevas redes o técnicas es mejor crear un conjunto de datos personalizado y escalarlo con técnicas de aumentación de datos.[5]

De la misma manera, cabe aclarar que gracias al artículo científico publicado de la revista “Computerized Medical Imaging and Graphics (Vol. 78)” demostró que Resnet50 comparada con las demás como (AlexNet, Vgg-16, Resnet-18 y Resnet-34) obtuvo mejores resultados en el ámbito de la medicina para el análisis de imágenes y detección de anomalías en resonancias magnéticas y similares como lo son las de rayos x.[14]

- **Validación empírica:** Se evaluará la precisión y efectividad del entrenamiento.
- **Validación en métricas:** Se evaluará la precisión y efectividad del entrenamiento con los resultados de las métricas como lo son el Modelo Accuracy y La Matriz de confusión.

- **Recolección de datos:** Se obtuvieron un conjunto de imágenes médicas apropiadas y disponibles en un dataset de KAGGLE en internet, que limpiamos y validamos su usabilidad mediante el siguiente fragmento de código:

```
import os
from PIL import Image, ImageStat, UnidentifiedImageError
import shutil

# -----
# CONFIGURACIÓN
# -----
# Ruta principal del dataset
DATASET_DIR = "/home/arlequin/workspace/Bone-Fracture-Detection/Dataset"
# Carpeta donde se guardarán imágenes inválidas (para revisión)
QUARANTINE_DIR = "/home/arlequin/workspace/Bone-Fracture-Detection/InvalidImages"

# Crea la carpeta de cuarentena si no existe
os.makedirs(QUARANTINE_DIR, exist_ok=True)

# -----
# FUNCIONES DE VALIDACIÓN
# -----
def is_damaged(path: str) -> bool:
    """Verifica si la imagen está dañada o no puede abrirse."""
    try:
        with Image.open(path) as img:
            img.verify()
        return False
    except (UnidentifiedImageError, OSError):
        return True

def is_empty_or_black(path: str, threshold: float = 5.0) -> bool:
    """Verifica si la imagen está vacía o negra (muy oscura)."""
    try:
        with Image.open(path) as img:
            img = img.convert("L")
            stat = ImageStat.Stat(img)
            mean_brightness = stat.mean[0]
            return mean_brightness < threshold
    except Exception:
        return True

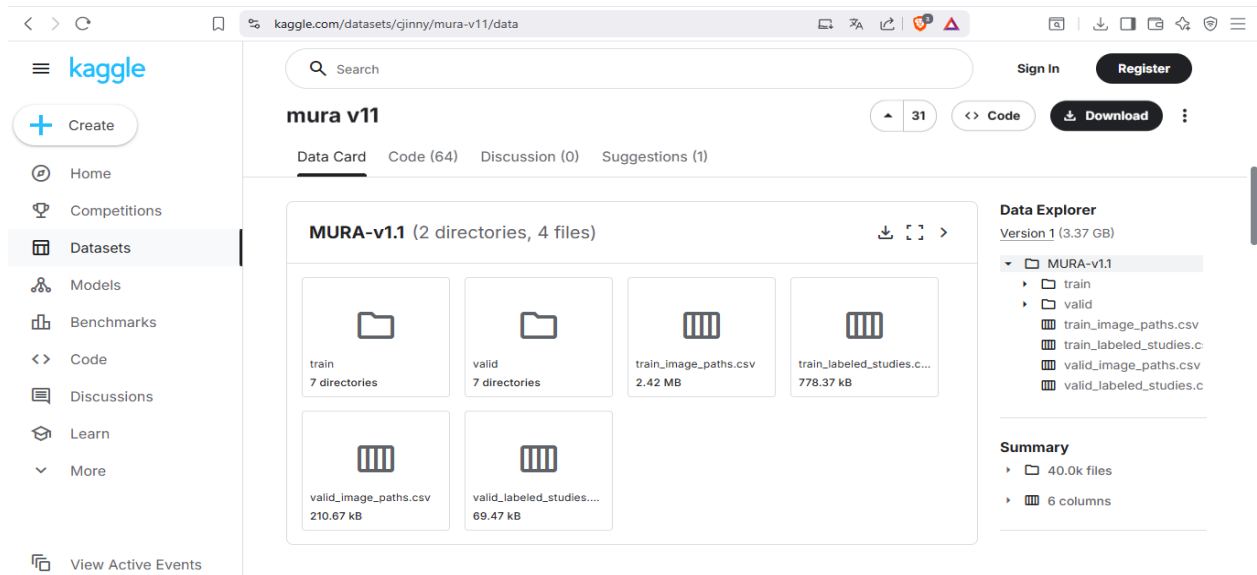
# -----
# PROCESO DE LIMPIEZA
# -----
def clean_dataset(dataset_dir=DATASET_DIR):
    print("🌀 Iniciando validación de imágenes...")
    total = 0
    removed = 0
    for root, _, files in os.walk(dataset_dir):
        for filename in files:
            if filename.lower().endswith((".jpg", ".jpeg", ".png", ".webp")):
                total += 1
                path = os.path.join(root, filename)

                if is_damaged(path) or is_empty_or_black(path):
                    removed += 1
                    print(f"⚠️ Imagen inválida detectada: {path}")
                    # Mover a cuarentena
                    dest = os.path.join(
                        QUARANTINE_DIR, os.path.relpath(path, dataset_dir)
                    )
                    os.makedirs(os.path.dirname(dest), exist_ok=True)
                    shutil.move(path, dest)

    print("Proceso completado")
    print(f"Total de imágenes analizadas: {total}")
    print(f"Imágenes movidas a cuarentena: {removed}")
    print(f"Imágenes válidas restantes: {total - removed}")

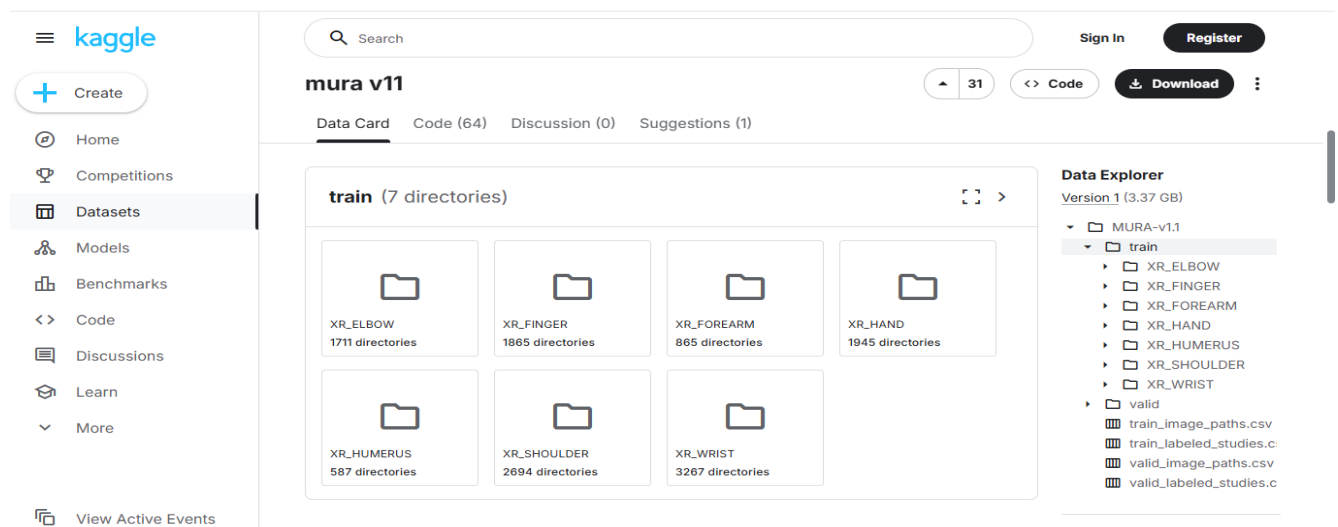
if __name__ == "__main__":
    clean_dataset()
```

KAGGLE que es una fuente confiable que permite utilizar Dataset específicos para hacer entrenamiento de redes neuronales, se escogió MURA V11 debido a sus constantes aportes de la comunidad a su mejoramiento y cantidad de imágenes que nos proporciona



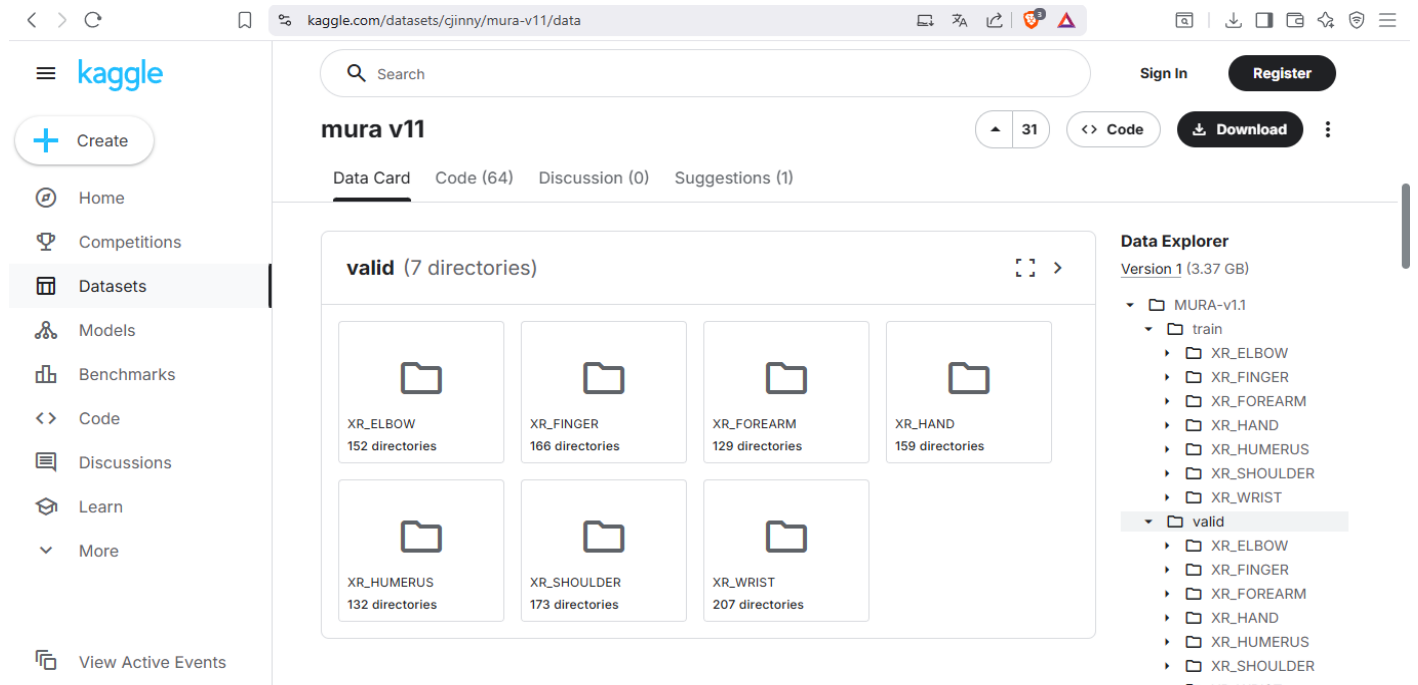
The screenshot shows the Kaggle interface for the MURA v11 dataset. The main content area displays the root directory structure under the heading "MURA-v1.1 (2 directories, 4 files)". It contains six items: a "train" folder with 7 directories, a "valid" folder with 7 directories, a "train\_image\_paths.csv" file (2.42 MB), a "train\_labeled\_studies.c..." file (778.37 kB), a "valid\_image\_paths.csv" file (210.67 kB), and a "valid\_labeled\_studies...." file (69.47 kB). On the right, the "Data Explorer" sidebar shows a tree view of the dataset structure, including the "train" and "valid" folders and their respective CSV files. The "Summary" section indicates there are 40.0k files and 6 columns.

Se utilizan dos carpetas, una para entrenar llamada TRAIN



The screenshot shows the Kaggle interface for the MURA v11 dataset, specifically focusing on the "train" directory. The main content area displays the "train (7 directories)" structure, containing seven sub-directories: "XR\_ELBOW" (1711 directories), "XR\_FINGER" (1865 directories), "XR\_FOREARM" (865 directories), "XR\_HAND" (1945 directories), "XR\_HUMERUS" (587 directories), "XR\_SHOULDER" (2694 directories), and "XR\_WRIST" (3267 directories). The "Data Explorer" sidebar on the right shows a tree view of the dataset structure, including the "train" folder and its sub-directories, as well as the "valid" folder and its associated CSV files.

La otra es VALID que tiene como objetivo la validación de los resultados del entrenamiento que tiene numerosas subcarpetas de información



The screenshot shows the Kaggle dataset page for 'mura v11'. The main content area displays the 'valid' directory, which contains 7 sub-directories: XR\_ELBOW (152 directories), XR\_FINGER (166 directories), XR\_FOREARM (129 directories), XR\_HAND (159 directories), XR\_HUMERUS (132 directories), XR\_SHOULDER (173 directories), and XR\_WRIST (207 directories). The right sidebar shows the 'Data Explorer' for 'MURA-v1.1', which is Version 1 (3.37 GB). The explorer shows a tree structure with 'train' and 'valid' folders. The 'train' folder contains sub-folders for XR\_ELBOW, XR\_FINGER, XR\_FOREARM, XR\_HAND, XR\_HUMERUS, XR\_SHOULDER, and XR\_WRIST. The 'valid' folder is currently selected and shows the same sub-folders.

También se utiliza las siguientes fuentes de información para aportar resultados:

- Algoritmos de preprocesamiento y análisis (Python, librerías como OpenCV, TensorFlow/Keras).
- Registro de métricas (Matplotlib) durante el entrenamiento y prueba del modelo.

- **Preprocesamiento de imágenes:** Las imágenes serán normalizadas, aplicando técnicas de procesamiento de imágenes como escalado, aumentación de datos por código

```
# get image and model name, the default model is "Parts"
# Parts - bone type predict model of 3 classes
# otherwise - fracture predict for each part
def predict(img, model="Parts"):
    size = 224
    if model == 'Parts':
        chosen_model = model_parts
    else:
        if model == 'Elbow':
            chosen_model = model_elbow_frac
        elif model == 'Hand':
            chosen_model = model_hand_frac
        elif model == 'Shoulder':
            chosen_model = model_shoulder_frac

    # load image with 224px224p (the training model image size, rgb)
    temp_img = image.load_img(img, target_size=(size, size))
    x = image.img_to_array(temp_img)
    x = np.expand_dims(x, axis=0)
    images = np.vstack([x])
    prediction = np.argmax(chosen_model.predict(images), axis=1)

    # chose the category and get the string prediction
    if model == 'Parts':
        prediction_str = categories_parts[prediction.item()]
    else:
        prediction_str = categories_fracture[prediction.item()]

    return prediction_str
```

- **Pruebas de Profesionales:** Se llevarán a cabo validaciones de médicos expertos que nos darán sus opiniones al respecto.

 UNIVERSIDAD Popular del Cesar

## PERFIL PROFESIONAL




**ANIBAL RAÚL ACUÑA MARTÍNEZ**  
CC 77481627  
Médico Internista

**ANIBAL ACUÑA MARTINEZ**  
MEDICO INTERNISTA  
UNIVERSIDAD ESTATAL DE GUAYAQUIL  
CC 77181627  
CONTACTO: 3506003205  
VALLEDUPAR

**ESPECIALIDADES MEDICAS:**  
MEDICINA GENERAL Y DE URGENCIAS  
DIABETOLOGÍA HIPERTENSIÓN ARTERIAL  
MEDICINA INTERNA  
EXPERTO EN ENFERMEDADES REUMATOLÓGICAS  
DIPLOMADOS EN UCI Y DISLIPIDEMIAS



**EXPERIENCIA  
MEDICA:  
20 AÑOS**

 UNIVERSIDAD Popular del Cesar

## PERFIL PROFESIONAL

**WISTON ALBERTO BAUTE REDONDO**  
MEDICO CIRUJANO  
CC 77006455  
CONTACTO: +52 5585942237  
CIUDAD DE MEXICO

**ESPECIALIDADES MEDICAS:**  
MEDICINA GENERAL Y DE URGENCIAS  
ESPECIALISTA MEDICINA ALTERNATIVA  
CIRUGIA(UNAM) - CIRUGIA ESTETICA  
POSTGRADO EN DERMATOLOGIA  
SEMINARIO EN TERAPIAS OSTEOMUSCULARES




**WISTON ALBERTO BAUTE REDONDO**  
CC 77006455  
Médico Cirujano  
UNIVERSIDAD NACIONAL AUTONOMA DE MÉXICO



**EXPERIENCIA  
MEDICA:  
40 AÑOS**

**Población:**

20.335 imágenes de rx de pacientes desconocidos de un banco de datos de uso libre de KAGGLE aprobado su viabilidad y pertinencia por nuestro personal médico.

**Muestra:**

20.322 imágenes de mano, hombro y codo resultado del preprocesamiento y normalización del dataset anteriormente mencionado.

## SECCIÓN III. DESARROLLO CIENTÍFICO TECNOLÓGICO.

### 3.1 DESARROLLO DE LAS FASES DE LA METODOLOGÍA PROPUESTA.

Se considera que basado en los objetivos que se requieren alcanzar y la capacidad humana que hay para el desarrollo del proyecto se escoge la **Metodología XP**, la cual se soporta en los siguientes aspectos y fases de desarrollo

#### 3.1.1 Justificación de la metodología XP

- Se eligió XP por ser una metodología ágil, adaptable y adecuada para equipos pequeños.
- Permite una rápida retroalimentación, desarrollo iterativo e integración continua, estas características son ideales para este proyecto que se caracteriza por un alto componente de experimentación como los de inteligencia artificial.
- En Inteligencia Artificial los resultados pueden cambiar según los datos o modelos, por lo que XP se ajusta bien al enfoque de prueba-error-control.
- Se considera una de las mejores metodologías para programación en pareja.

### 3.1.2 Fases y prácticas aplicadas de XP

Las fases de este proyecto quedaron estructuradas de la siguiente manera:

#### 3.1.2.1 PLANIFICACIÓN

Se busca definir funcionalidades (historias de usuario) y priorizarlas según valor y complejidad.

#### HISTORIAS DE USUARIOS (REQUISITOS FUNCIONALES)

Elemento	Descripción
<b>Nombre</b>	Inicio de sesión seguro
<b>ID</b>	HU-01
<b>Actor</b>	Administrador
<b>Rol del actor</b>	Accede al sistema con credenciales válidas
<b>Necesidad</b>	Ingresar al sistema de manera segura
<b>Historia de usuario</b>	Como usuario del sistema, quiero iniciar sesión con usuario y contraseña para acceder a las funcionalidades del sistema.
<b>Requisito funcional asociado</b>	RF-01: El sistema debe permitir login con validación de credenciales.
<b>Criterios de aceptación</b>	<ul style="list-style-type: none"><li>✓ Inicia la aplicación</li><li>✓ Ingresa Usuario Y contraseña</li><li>✓ Se valida los datos</li><li>✓ Accede exitosamente al dashboard</li></ul>
<b>Prioridad</b>	Alta
<b>Excepciones</b>	E-1: Login fallido muestra mensaje de error, se revalidan datos E-2: El usuario no está registrado en el sistema, envía error de acceso

Elemento	Descripción
<b>ID</b>	HU-02-03
<b>Nombre</b>	Registro de datos del paciente
<b>Actor</b>	Administrador
<b>Rol del actor</b>	Registrar los datos personales y clínicos del paciente antes del análisis
<b>Historia de usuario</b>	Como profesional de la salud autenticado quiero registrar los datos básicos y clínicos del paciente para asociar esta información al análisis de la imagen.
<b>Requisitos funcionales asociados</b>	<b>RF-02:</b> El sistema debe permitir registrar y guardar los datos del paciente antes del análisis. <b>RF-03:</b> Los datos deben vincularse correctamente al resultado del diagnóstico.
<b>Criterios de aceptación</b>	<ul style="list-style-type: none"> <li>✓ El formulario de registro contiene campos obligatorios como nombre, edad, sexo y antecedentes médicos.</li> <li>✓ El sistema valida que todos los campos requeridos estén completos.</li> <li>✓ Los datos se almacenan correctamente y se relacionan con la imagen cargada.</li> <li>✓ Se puede consultar el historial de un paciente en futuras sesiones.</li> </ul>
<b>Escenario principal</b>	<ol style="list-style-type: none"> <li>1. Usuario inicia sesión y accede al formulario de nuevo paciente.</li> <li>2. Completa los datos solicitados (Tipo y número de documento, nombre, apellido y fecha).</li> <li>3. El sistema valida los campos.</li> <li>4. El paciente queda registrado y listo para asociar una imagen y diagnóstico.</li> </ol>
<b>Caminos alternativos o excepcionales</b>	<p><b>E-1:</b> Si falta un campo obligatorio → se muestra advertencia y no permite guardar</p> <p><b>E-2:</b> Si se intenta registrar un paciente ya existente → el sistema sugiere actualizar los datos.</p> <p><b>E-3:</b> Si se cae la conexión → los datos no se pierden y se ofrece reintentar el registro.</p>
<b>Prioridad</b>	Alta
<b>Iteración estimada (XP)</b>	Iteración 1 (estructura de datos y entrada de información inicial)


Elemento	Descripción
<b>ID</b>	HU-04-05
<b>Nombre</b>	Cargar imagen médica y recibir diagnóstico automatizado
<b>Actor</b>	Administrador
<b>Rol del actor</b>	Cargar una imagen médica (radiografía) para su análisis
<b>Historia de usuario</b>	Como profesional de la salud autenticado quiero cargar una imagen radiológica del paciente para que el sistema la analice mediante IA y me entregue un diagnóstico con nivel de confianza y atención sugerida.
<b>Requisitos funcionales asociados</b>	<p><b>RF-04:</b> El sistema debe permitir la carga de imágenes válidas (JPG, PNG).</p> <p><b>RF-05:</b> El sistema debe procesar la imagen y generar un diagnóstico automático.</p>
<b>Criterios de aceptación</b>	<ul style="list-style-type: none"> <li>✓ El sistema permite seleccionar y subir una imagen válida.</li> <li>✓ Se valida formato y tamaño.</li> <li>✓ El sistema inicia automáticamente el análisis IA.</li> <li>✓ Se muestra resultado: "fractura" o "sin fractura".</li> <li>✓ Se incluye porcentaje de confianza.</li> <li>✓ Se sugiere tipo de atención médica.</li> </ul>
<b>Escenario principal</b>	<ol style="list-style-type: none"> <li>1. Usuario accede al sistema y selecciona una imagen.</li> <li>2. El sistema valida y carga la imagen.</li> <li>3. Se inicia el procesamiento con IA.</li> <li>4. Se muestra diagnóstico con nivel de certeza y recomendación médica.</li> </ol>
<b>Caminos alternativos o excepcionales</b>	<p><b>E-1:</b> Archivo muy grande o formato incorrecto → mensaje de error.</p> <p><b>E-2:</b> Imagen dañada o ilegible → sistema solicita nueva carga.</p> <p><b>E-3:</b> Fallo de red durante carga → opción de reintentar.- Modelo IA sin diagnóstico claro → advertencia y sugerencia de revisión manual.</p>
<b>Prioridad</b>	Alta
<b>Iteración estimada (XP)</b>	Iteraciones 2 y 3 (Diseño e implementación del módulo central)

## REQUISITOS NO FUNCIONALES

Se hacen pruebas para saber requisitos como seguridad y eficacia por código apoyado en la herramienta SonarQube



- 1) Diagnóstico del funcionamiento del aplicativo arrojando el primer resultado general:

SonarQube muestra una alta calidad de código, con calificaciones A en seguridad, fiabilidad y mantenibilidad, sin vulnerabilidades ni errores críticos, la cobertura del 12.7 % refleja pruebas iniciales que deben ampliarse, mientras que el 3.7 % de duplicación indica buena reutilización del código, los dos hotspots de seguridad no representan riesgos activos, en general, el sistema demuestra ser seguro, estable y mantenible, con una arquitectura sólida y adecuada para su uso en entornos de diagnóstico médico con inteligencia artificial.



2) Se muestra a detalle el resultado de las unidades más importantes analizadas del aplicativo

El análisis de seguridad evidencia ausencia de vulnerabilidades críticas y un cumplimiento adecuado de las reglas OWASP, el sistema implementa buenas prácticas de autenticación y manejo de datos, reduciendo el riesgo de exposición o ejecución de código inseguro.



Con un índice de 3.7 % de duplicación, el sistema muestra una alta eficiencia en la reutilización de código y bajo nivel de redundancia, esto refleja una correcta aplicación de patrones de diseño y refactorización, optimizando la legibilidad y el rendimiento del proyecto.

The screenshot shows the SonarQube interface for a project named 'Bone Fracture Detection'. The 'Measures' tab is active, and the 'Duplications' section is highlighted. The main content area displays 'Duplicated Lines (%) 3.7%' with a 'See history' link and a 'New Code: Since October 8, 2025' indicator. Below this, a table lists files with their respective duplicated line percentages and counts:

File	Duplicated Lines (%)	Duplicated Lines
training_parts.py	41.4%	70
training_fracture.py	37.2%	71

At the bottom of the table, there is a note: 'There are 38 hidden components with a score of 0.0%' and a 'Show Them' button.

Se observan 15 issues abiertos, principalmente de tipo “code smell”, los cuales no representan fallas críticas, el sistema conserva una arquitectura modular, facilitando el mantenimiento evolutivo y la integración de nuevos modelos IA, la calificación A indica que el código sigue principios de calidad como cohesión, bajo acoplamiento y claridad funcional.

The screenshot shows the SonarQube interface for the same project, 'Bone Fracture Detection'. The 'Measures' tab is active, and the 'Maintainability' section is highlighted. The main content area displays 'Issues 15' with a 'See history' link and a 'New Code: Since October 8, 2025' indicator. Below this, a table lists files with their respective issue counts:

File	Issues
training_fracture.py	4
prediction_test.py	3
training_parts.py	3
app/Views/main_content_widget.py	2
main2.py	1
normalization.py	1

On the left sidebar, the 'Maintainability' section shows an overall rating of 'A' and '15 Issues'.

### 3.1.2.2 DISEÑO:

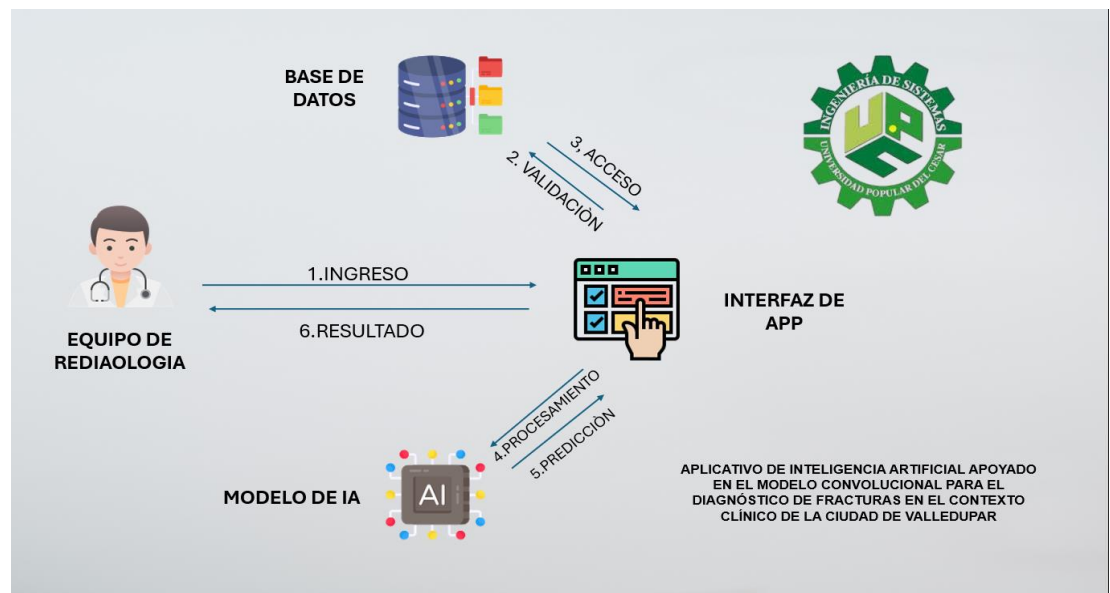
SE DOCUMENTAN LOS CASOS DE USO:

<b>ID</b>	<b>Nombre del Caso de Uso</b>	<b>Actor Principal</b>	<b>Descripción</b>	<b>Prioridad</b>
<b>CU-01</b>	Iniciar sesión	Administrador	El usuario accede al sistema ingresando su nombre de usuario y contraseña previamente registrados.	ALTA
<b>CU-02</b>	Registrar usuario	Administrador	El administrador valida la solicitud de ingreso y registra al usuario en el sistema.	ALTA
<b>CU-03</b>	Registrar datos del paciente	Administrador	El usuario diligencia un formulario con los datos básicos del paciente antes de cargar la imagen médica.	ALTA
<b>CU-04</b>	Cargar imagen médica	Administrador	El usuario carga una imagen médica (radiografía u otra) para ser procesada por el sistema.	ALTA
<b>CU-05</b>	Procesar imagen con IA	Sistema (IA)	El sistema procesa automáticamente la imagen cargada, identifica si existe fractura o no, y arroja un diagnóstico.	ALTA
<b>CU-06</b>	Mostrar resultado y tipo de atención	Sistema	El sistema muestra el diagnóstico al usuario y sugiere un tipo de atención médica según el resultado.	ALTA

## ARQUITECTURA DE ALTO NIVEL:

Se utilizó python para la codificación y entrenamiento del modelo con el apoyo de las siguientes librerías en sus diferentes versiones:

- customtkinter~=5.0.3
- PyAutoGUI~=0.9.53
- PyGetWindow~=0.0.9
- Pillow~=8.4.0
- numpy~=1.19.5
- tensorflow~=2.6.2
- keras~=2.6.0
- pandas~=1.1.5
- matplotlib~=3.3.4
- scikit-learn~=0.24.2
- colorama~=0.4.5
- pyside6




### 3.1.2.3 CODIFICACIÓN:

Basado en la metodología propuesta se organizaban sesiones compartidas donde uno programaba y el otro revisaba en tiempo real.

En momentos de trabajo individual, se revisaba luego en conjunto con control de versiones, se deja plasmado el avance del proyecto en los diferentes commits en el siguiente repositorio de Github:

<https://github.com/juadadev/Fracturas-app>



### 3.1.2.5 PRUEBAS

Se realizan pruebas unitarias y de integración para verificar la funcionalidad del aplicativo, todas estas mediante código

```
import sys
import os
import unittest
from unittest.mock import patch

import pytest
from PySide6.QtWidgets import QApplication
from PySide6.QtGui import QPixmap, QImage
from PySide6.QtCore import QSize

# Agrega el directorio de la aplicación a la ruta de Python
sys.path.insert(0, os.path.abspath(os.path.join(os.path.dirname(__file__), "..")))
from app.views.main_content_widget import MainContentWidget

# Fixture para proporcionar una instancia de QApplication
@pytest.fixture(scope="session")
def qt_app():
    app = QApplication.instance()
    if app is None:
        app = QApplication(sys.argv)
    yield app
    app.quit()

@pytest.mark.usefixtures("qt_app")
class TestMainContentWidget(unittest.TestCase):
    def setUp(self):
        """Configura el entorno de prueba"""
        self.widget = MainContentWidget()

        # Simula los datos del paciente
        self.widget.combo_doc_type.setCurrentIndex(0) # C.C
        self.widget.txt_doc_number.setText("1005845554")
        self.widget.txt_name.setText("WILSON")
        self.widget.txt_lastname.setText("BAUTE")

        # Simula el resultado de la predicción
        self.widget.prediction_result = {
            "Fracture": "Resultado: Fracturado (confianza 92.0%)",
            "type": "Tipo: Shoulder (confianza 95.0%)",
            "risk": "Riesgo: Alto (score=0.95)",
            "priority": "Prioridad: Atención inmediata",
            "box": [10, 20, 100, 120],
        }
        text_values = {
            k: v for k, v in self.widget.prediction_result.items() if k != "box"
        }
        self.widget.text_area_label.setText("\n".join(text_values.values()))

        # Simula la imagen
        self.widget.filename = "/fake/path/to/image.png"
        # Crea un QPixmap de prueba
        image = QImage(QSize(200, 200), QImage.Format.Format_RGB32)
        image.fill(0) # Imagen negra
        pixmap = QPixmap.fromImage(image)
        self.widget.img_label.setPixmap(pixmap)

    @patch("app.views.main_content_widget.QMessageBox")
    def test_generate_pdf_report_success(self, mock_message_box):
        """
        Prueba la generación exitosa de un informe en PDF.
        """
        temp_pdf_path = "test_report.pdf"

        # Asegura que el archivo no exista antes de la prueba
        if os.path.exists(temp_pdf_path):
            os.remove(temp_pdf_path)

        # Llama al método que se va a probar
        self.widget.generate_pdf_report(temp_pdf_path)

        # Verifica que el archivo PDF fue creado
        self.assertTrue(os.path.exists(temp_pdf_path))
        self.assertTrue(os.path.getsize(temp_pdf_path) > 0)

        # Verifica que se mostró el mensaje de éxito
        mock_message_box.information.assert_called_once()

        # Limpia el archivo creado
        if os.path.exists(temp_pdf_path):
            os.remove(temp_pdf_path)

    @patch("app.views.main_content_widget.QMessageBox")
    def test_generate_pdf_report_no_result(self, mock_message_box):
        """
        Prueba el fallo en la generación de PDF cuando no hay resultado de predicción.
        """
        self.widget.prediction_result = None
        temp_pdf_path = "test_report_fail.pdf"

        self.widget.generate_pdf_report(temp_pdf_path)

        # Verifica que el PDF no fue creado
        self.assertFalse(os.path.exists(temp_pdf_path))

        # Verifica que se mostró un mensaje crítico
        mock_message_box.critical.assert_called_once()

    def tearDown(self):
        """Limpia después de las pruebas"""
        # Limpia cualquier archivo temporal si existe
        if os.path.exists("temp_report_image.png"):
            os.remove("temp_report_image.png")
        if os.path.exists("temp_logo.png"):
            os.remove("temp_logo.png")

if __name__ == "__main__":
    pytest.main()
```

## Pruebas Unitarias:

- 1) En test\_predict.py, se prueba que la lógica de predicción clasifique correctamente una imagen como "Hombro" y "Fracturado", validando que los cálculos sean correctos.
- 2) En test\_main\_content\_widget.py, se prueba que el botón "Generar Reporte PDF" cree un archivo válido con los datos del paciente y el resultado del diagnóstico.

## Pruebas De Integración:

- 1) En test\_login\_controller.py, se simula un inicio de sesión para asegurar que la vista (UI), el controlador (lógica) y el autenticador se comunican bien para validar o rechazar a un usuario,

### 3.1.2.6 IMPLEMENTACIÓN



## **3.2 ANÁLISIS DE RESULTADOS Y DISCUSIÓN.**

En relación con los objetivos planteados para el desarrollo del proyecto de detección de fracturas mediante inteligencia artificial, los resultados esperados son los siguientes:

### **3.2.1 Recolección del conjunto de imágenes:**

Se recolectó un extenso conjunto de imágenes de rayos X de mano, codo y hombro, se llevó a cabo mediante la exploración y descarga de múltiples imágenes de un dataset público disponible en internet para fines educativos, siendo la plataforma Kaggle una fuente primordial para nuestra recolección de datos.

De la misma manera la agregación de datos provenientes de diversos aportes de la comunidad al dataset permitió construir un conjunto robusto de imágenes considerablemente amplio para el entrenamiento efectivo de un modelo de inteligencia artificial capaz de cumplir con los objetivos de detección

### **3.2.2 Dificultades durante la recolección:**

En el proceso de recopilación dichas imágenes desde diversas fuentes en línea se identificaron los siguientes desafíos:

- **Variedad en Formatos y Calidad:** La inconsistencia en los formatos de archivo y la calidad de las imágenes entre diferentes carpetas dificultaba su integración, por lo que se unificaron formatos y se aplicaron criterios de selección por código para descargar imágenes con errores o dañadas, al mismo tiempo se estableció un fragmento de código que normaliza todas las imágenes a 224 píxeles.


• Desbalance de Datos: Algunas carpetas presentaban una proporción desigual entre imágenes con y sin fractura, esto podía afectar el rendimiento del modelo, por lo que se aumentaron el número de registros en la clase minoritaria (imágenes con fracturas) para así lograr equilibrar el conjunto de entrenamiento.

### 3.2.3 Preparación del conjunto de datos:

Se logró realizar un análisis exhaustivo del conjunto de datos médicos seleccionados, todo esto con el fin de garantizar que estos cumplieran con los requisitos de calidad, relevancia y representatividad necesarios para el entrenamiento efectivo de la red neuronal

Se crean 3 carpetas respectivamente para cada tipo de radiografía

- ✓ **MANO**
- ✓ **HOMBRO**
- ✓ **CODO**



Part	Normal	Fractured	Total
Elbow	3160	2236	5396
Hand	4330	1673	6003
Shoulder	4496	4440	8936

Dentro de cada una existe una subcategoría de NORMAL y FRACTURADA para poder entrenar el modelo con un total de 20.335, después de realizado el análisis exploratorio de las imágenes donde se efectuaron limpieza, normalización y filtros quedó una muestra representativa de 20.322 imágenes.

Se completó exitosamente la preparación y preprocesamiento de las imágenes médicas aplicando técnicas de normalización, aumentación de datos y segmentación cuando fue necesario, se crea una parte específica del código que resécala las imágenes a 224 pixeles para poder manejar todas las imágenes con la misma estructura.

```
# get image and model name, the default model is "Parts"
# Parts - bone type predict model of 3 classes
# otherwise - fracture predict for each part
def predict(img, model="Parts"):
    size = 224
    if model == 'Parts':
        chosen_model = model_parts
    else:
        if model == 'Elbow':
            chosen_model = model_elbow_frac
        elif model == 'Hand':
            chosen_model = model_hand_frac
        elif model == 'Shoulder':
            chosen_model = model_shoulder_frac

    # load image with 224px224p (the training model image size, rgb)
    temp_img = image.load_img(img, target_size=(size, size))
    x = image.img_to_array(temp_img)
    x = np.expand_dims(x, axis=0)
    images = np.vstack([x])
    prediction = np.argmax(chosen_model.predict(images), axis=1)

    # chose the category and get the string prediction
    if model == 'Parts':
        prediction_str = categories_parts[prediction.item()]
    else:
        prediction_str = categories_fracture[prediction.item()]

    return prediction_str
```

### 3.2.3.1 Entrenamiento de la red neuronal:

- **PARTE 1:**

Lo primero es dividir las imágenes en dos partes, como se detalla a continuación:

El porcentaje de imágenes que se usaron para el entrenamiento son 2 divisiones diferentes de los datos.

#### ***1. Primera división:***

train\_test\_split (90% / 10%)

TOTAL DE IMÁGENES:

90% para entrenar (NUMERO DE IMÁGENES) y 10% para test (NUMERO DE IMÁGENES)

```
train_df, test_df = train_test_split(images, train_size=0.9,  
stratify=images["class"], random_state=1)
```

Aquí se divide el conjunto completo de imágenes (images) en:

90% para entrenamiento + validación (train\_df)

10% para prueba final (test\_df)

Esta prueba final (test\_df) no se toca durante el entrenamiento. Sirve solo para evaluar al final.

## **2. Segunda división:**

ImageDataGenerator con validation\_split=0.2 75%, 20% y la última para test

```
train_images = train_generator.flow_from_dataframe(  
    dataframe=train_df,  
    ...  
    subset='training' # 80% de train_df (el 72% del total)  
)
```

```
val_images = train_generator.flow_from_dataframe(  
    dataframe=train_df,  
    ...  
    subset='validation' # 20% de train_df (el 18% del total)  
)
```

```
test_images = test_generator.flow_from_dataframe(  
    dataframe=test_df, # Aquí se usa el 10% original  
    x_col='Filepath',  
    y_col='Label',  
    target_size=(224, 224),  
    color_mode='rgb',  
    class_mode='categorical',  
    batch_size=32,  
    shuffle=False  
)
```

- **PARTE 2:**

La siguiente línea de código muestra el pre-entrenamiento del modelo:

```
pretrained_model = tf.keras.applications.resnet50.ResNet50(  
    input_shape=(224, 224, 3),  
    include_top=False,  
    weights='imagenet',  
    pooling='avg')
```

Se usa ResNet50 pre-entrenada sin la parte superior (include\_top=False), con un GlobalAveragePooling2D (pooling='avg').

Este modelo tiene cientos de capas internas (convolucionales, activaciones, batchnorm, etc.), pero para nuestro modelo final solo usamos su salida, no lo entrenamos (trainable = False).

- **PARTE 3:**

Para el entrenamiento Definitivo se plantea un modelo de 3 capas distribuidas de la siguiente manera :

```
x = tf.keras.layers.Dense(128, activation='relu')(pretrained_model.output)
```

**# 128 neuronas**

```
x = tf.keras.layers.Dense(50, activation='relu')(x)
```

**# 50 neuronas**

```
outputs = tf.keras.layers.Dense(2, activation='softmax')(x)
```

**# 2 neuronas**

Este es el modelo que más aciertos esperados tuvo durante las pruebas previas, por lo tanto, el que se utiliza para integrarlo con el aplicativo.


### 3.2.4 Validación del aplicativo con datos clínicos

El aplicativo fue validado utilizando un conjunto independiente de imágenes de rayos x aprobados por nuestro asesor y cuerpo médico, los resultados demostraron que el modelo alcanzó un alto nivel de precisión en la detección de fracturas, con tiempos de respuesta adecuados.

Durante los entrenamientos se sacaron graficas en donde se evidencia los resultados de las métricas:

#### ✓ **METRICA 1:**

El porcentaje de aciertos aumenta hasta llegar a puntos óptimos de más del 82% al ser entrenado y de 80% en el testeo del entrenamiento



### **Conclusiones basadas en los resultados:**

- La precisión en entrenamiento aumenta progresivamente de  $\sim 0.69$  en la época 1 hasta  $\sim 0.82$  en la época 19.
- La validación también mejora desde  $\sim 0.72$  hasta estabilizarse entre 0.77 y 0.80, aunque con fluctuaciones.
- En las primeras 5 épocas, el modelo incrementa la precisión rápidamente tanto en entrenamiento como en validación, lo que indica que está captando patrones relevantes en los datos.
- Después de la época 10, la curva de validación deja de crecer significativamente y oscila alrededor del 0.78–0.80, esto muestra que el modelo ya alcanzó una meseta en su capacidad de generalización.
- En la época 8–9, con una exactitud de  $\sim 79\%$ , antes de que aparezca la caída.
- En la época 15, la precisión en entrenamiento sigue llega a su pico más alto (hasta 82%), por lo que se escogen esos pesos para el modelo.

El aplicativo arroja resultados positivos, basados en el modelo que se entrenó previamente

✓ **METRICA 2:**

MATRIZ DE CONFUSIÓN:

```
Hand Results:
[0.4717140197753906, 0.7853577136993408]
Test Accuracy: 78.54%
Confusion Matrix:
[[ 83 99]
 [ 30 389]]
Classification Report:
              precision    recall  f1-score   support

     0       0.73      0.46      0.56      182
     1       0.80      0.93      0.86      419

 accuracy          0.79
 macro avg          0.77
 weighted avg       0.78

Found 6434 validated image filenames belonging to 2 classes.
Found 1608 validated image filenames belonging to 2 classes.
Found 894 validated image filenames belonging to 2 classes.
```

[0.4717140197753906, 0.7853577136993408]

El primer valor corresponde a la pérdida (loss) y precisión (accuracy) del modelo en entrenamiento o evaluación.

El valor 0.7853  $\approx$  78.54% indica la precisión global del modelo en el conjunto de prueba.

Test Accuracy: 78.54% (Porcentaje de Aciertos)

El modelo acertó en aproximadamente 79 de cada 100 imágenes.

```
Hand Results:
[0.4717140197753906, 0.7853577136993408]
Test Accuracy: 78.54%
Confusion Matrix:
[[ 83 99]
 [ 30 389]]
```

Esto indica cómo el modelo clasificó las imágenes en dos clases:

0: Sin fractura    1: Con fractura

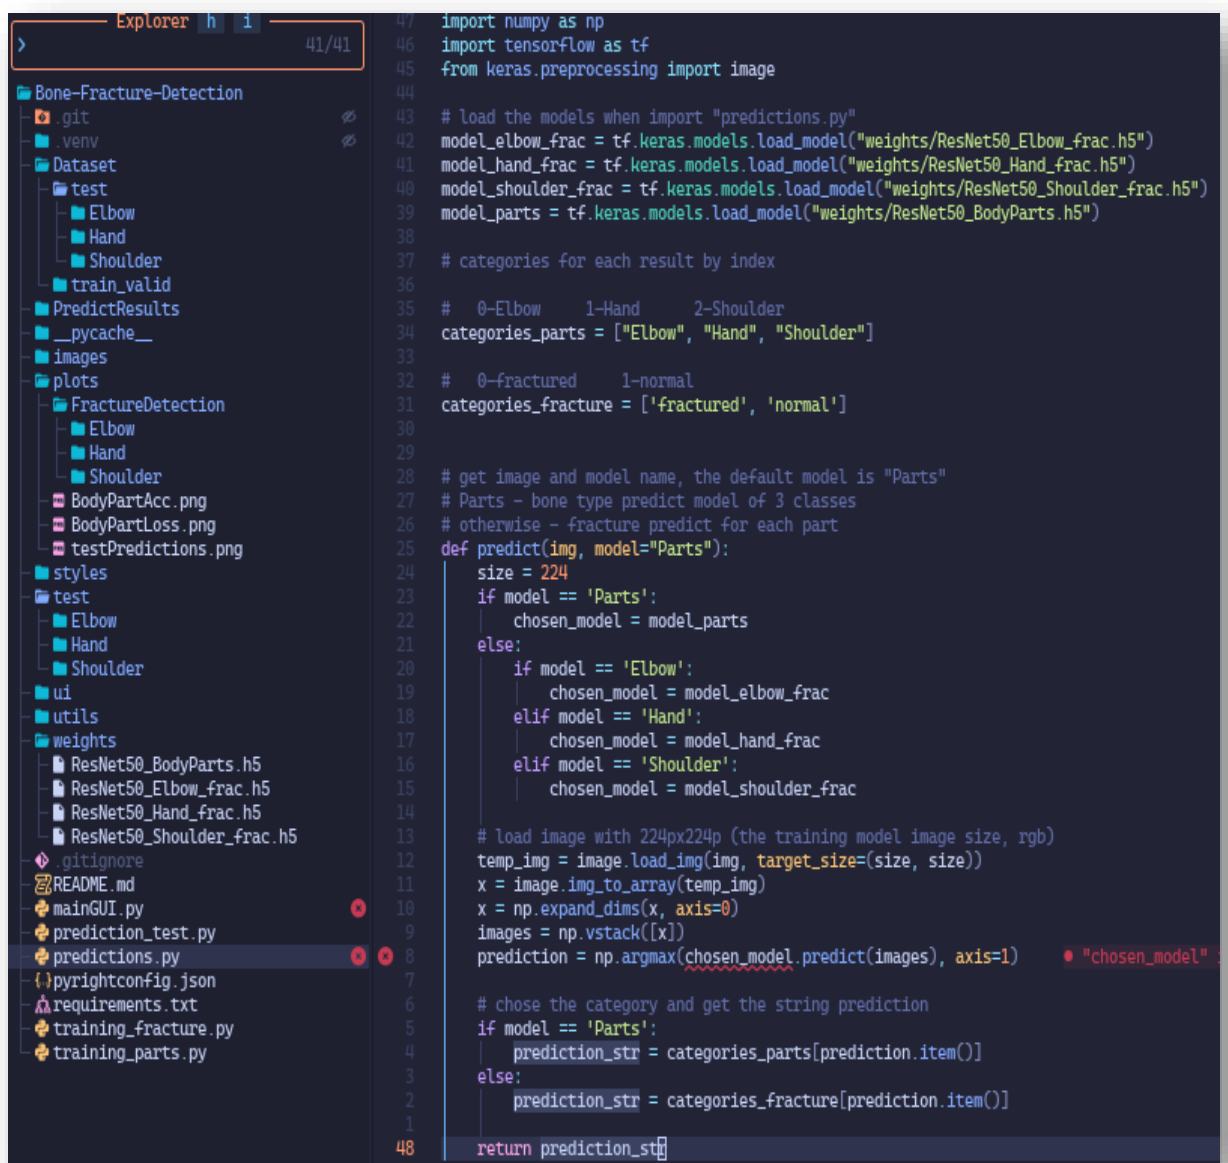
Predijo 0 (Sin fractura)    Predijo 1 (Con fractura)

Era 0 (sin fractura)    83 (✓) No Fracturados    99 (✗) Falsos positivos)

Era 1 (con fractura)    30 (✗) Falsos negativos)    389 (✓) Fracturados


### 3.2.5 Desarrollo del aplicativo e integrarlo con el modelo entrenado de inteligencia artificial:

Sé logró desarrollar un aplicativo funcional que integra el modelo de red neuronal convolucional entrenado, este permite al personal médico cargar imágenes, analizarlas y recibir un diagnóstico preliminar sobre la presencia de fracturas en mano, codo y hombro.



```
47 import numpy as np
48 import tensorflow as tf
49 from keras.preprocessing import image
50
51 # load the models when import "predictions.py"
52 model_elbow_frac = tf.keras.models.load_model("weights/ResNet50_Elbow_frac.h5")
53 model_hand_frac = tf.keras.models.load_model("weights/ResNet50_Hand_frac.h5")
54 model_shoulder_frac = tf.keras.models.load_model("weights/ResNet50_Shoulder_frac.h5")
55 model_parts = tf.keras.models.load_model("weights/ResNet50_BodyParts.h5")
56
57 # categories for each result by index
58
59 # 0-Elbow 1-Hand 2-Shoulder
60 categories_parts = ["Elbow", "Hand", "Shoulder"]
61
62 # 0-fractured 1-normal
63 categories_fracture = ['fractured', 'normal']
64
65 # get image and model name, the default model is "Parts"
66 # Parts - bone type predict model of 3 classes
67 # otherwise - fracture predict for each part
68 def predict(img, model="Parts"):
69     size = 224
70     if model == 'Parts':
71         chosen_model = model_parts
72     else:
73         if model == 'Elbow':
74             chosen_model = model_elbow_frac
75         elif model == 'Hand':
76             chosen_model = model_hand_frac
77         elif model == 'Shoulder':
78             chosen_model = model_shoulder_frac
79
80     # load image with 224px224p (the training model image size, rgb)
81     temp_img = image.load_img(img, target_size=(size, size))
82     x = image.img_to_array(temp_img)
83     x = np.expand_dims(x, axis=0)
84     images = np.vstack([x])
85     prediction = np.argmax(chosen_model.predict(images), axis=1) # "chosen_model":
86
87     # chose the category and get the string prediction
88     if model == 'Parts':
89         prediction_str = categories_parts[prediction.item()]
90     else:
91         prediction_str = categories_fracture[prediction.item()]
92
93     return prediction_str
```

## INTERFAZ DEL USUARIO:



AI-BONE X



**INFORMACIÓN DEL PACIENTE**

Tipo de documento  
C.C

10658344554

WISTON ALBERTO

BAUTE



Subir imagen

Resultado:  
Fracturado (confianza 79.9%)  
Tipo: Hand (confianza 100.0%)  
Riesgo: Medio (score=0.70)  
Prioridad: Atención prioritaria

Predecir

Descargar Informe

Cerrar sesión

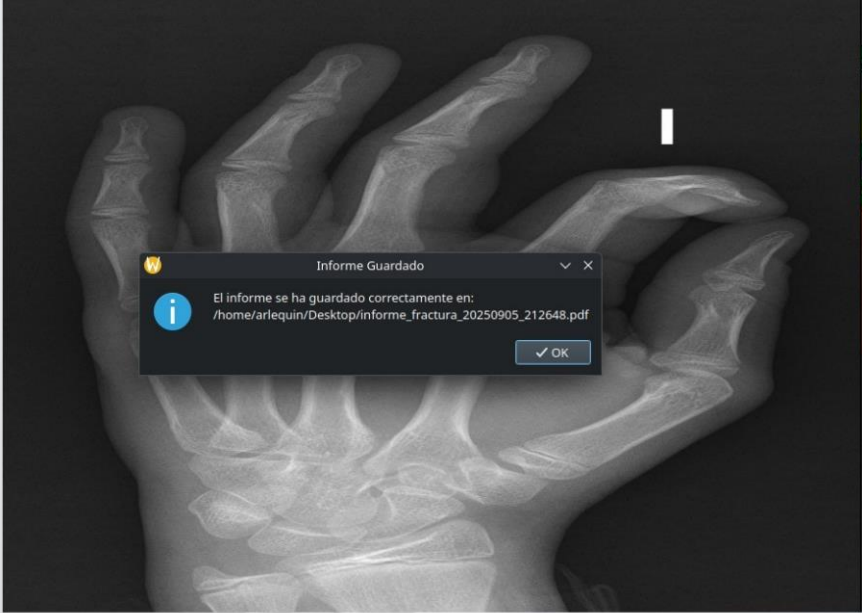
**INFORMACIÓN DEL PACIENTE**

Tipo de documento  
C.C

10655834556

LUIS CAMILO

ROJAS



Subir imagen

Resultado:  
Fracturado (confianza 79.9%)  
Tipo: Hand (confianza 100.0%)  
Riesgo: Medio (score=0.70)  
Prioridad: Atención prioritaria

Predecir

Descargar Informe

Cerrar sesión

Informe Guardado

El informe se ha guardado correctamente en:  
/home/arlequin/Desktop/informe\_fractura\_20250905\_212648.pdf

OK

informe\_fractura\_20250905\_212648.pdf — Okular

File View Edit Go Bookmarks Tools Settings Help

45.3% View Mode

1 of 2


Browse AI Text Selection Yellow Highlighter

### Informe de Detección de Fractura Ósea

**Datos del Paciente:**  
Tipo de Documento: C.C  
Número del Documento: 1065834056  
Nombre: LUIS CAMILO  
Apellido: ROJAS

**Resultados del Análisis:**  
Resultado: Fracturado (confianza 79.9%)  
Tipo: Hand (confianza 100.0%)  
Riesgo: Medio (score=0.70)  
Prioridad: Atención prioritaria

Imagen analizada con anotaciones:



Fecha del análisis: 2025-09-05 21:26:51

### 3.2.5 Validación del aplicativo por expertos médicos

 UNIVERSIDAD Popular del Cesar

## PERFIL PROFESIONAL



**ANIBAL ACUÑA MARTINEZ**  
MEDICO INTERNISTA  
UNIVERSIDAD ESTATAL DE GUAYAQUIL  
CC 77181627  
CONTACTO: 3506003205  
VALLEDUPAR

**EXPERIENCIA MEDICA:**  
20 AÑOS

  
**ANIBAL RAUL ACUÑA MARTINEZ**  
CC 77481627  
Médico Internista

**ESPECIALIDADES MEDICAS:**  
MEDICINA GENERAL Y DE URGENCIAS  
DIABETOLOGÍA HIPERTENSIÓN ARTERIAL  
MEDICINA INTERNA  
EXPERTO EN ENFERMEDADES REUMATOLÓGICAS  
DIPLOMADOS EN UCI Y DISLIPIDEMIAS



 UNIVERSIDAD Popular del Cesar

## PERFIL PROFESIONAL

**WISTON ALBERTO BAUTE REDONDO**  
MEDICO CIRUJANO  
CC 77006455  
CONTACTO: +52 5585942237  
CIUDAD DE MEXICO

**EXPERIENCIA MEDICA:**  
40 AÑOS

**ESPECIALIDADES MEDICAS:**  
MEDICINA GENERAL Y DE URGENCIAS  
ESPECIALISTA MEDICINA ALTERNATIVA  
CIRUGIA (UNAM) - CIRUGIA ESTETICA  
POSTGRADO EN DERMATOLOGIA  
SEMINARIO EN TERAPIAS OSTEOMUSCULARES



  
**WISTON ALBERTO BAUTE REDONDO**  
CC 77006455  
Médico Cirujano  
UNIVERSIDAD NACIONAL AUTONOMA DE MEXICO



## AVAL EXPERTO 1:

Soporte de entrevista en video:

<https://drive.google.com/file/d/1pv6mRvigLgBZotYSldZqvSaE8xLPySzW/view?usp=sharing>



**AVAL DE PROYECTO POR UN EXPERTO MÉDICO**

Valledupar, 31 De agosto De 2025.

Señores:  
**COMITÉ DE INVESTIGACIÓN**  
Facultad de Ingenierías y Tecnológicas  
Programa de Ingeniería de Sistemas  
Universidad Popular Del Cesar

Cordial saludo

Yo **ANIBAL RAUL ACUAÑA MARTINEZ**, identificado con la cédula de ciudadanía No. 77181627, Como MEDICO PROFESIONAL y ESPECIALISTA EN MEDICINA INTERNA certifico la VIABILIDAD Y FUNCIONALIDAD en el contexto clínico del aplicativo de proyecto de tesis como opción de grado para la universidad Popular del Cesar que lleva por título "AI-BONE X: APLICATIVO DE INTELIGENCIA ARTIFICIAL APOYADO EN EL MODELO CONVOLUCIONAL PARA EL DIAGNÓSTICO DE FRACTURAS EN EL CONTEXTO CLÍNICO DE LA CIUDAD DE VALLEDUPAR", presentada por los estudiantes de Ingeniería de Sistemas WISTON ALBERTO BAUTE BAUTISTA y JUAN DAVID AYALA PRIMO, así como la pertinencia del banco de datos utilizado por el mismo

**Línea de investigación:** Transformación Digital

**Sublínea:** Inteligencia Artificial

Agradezco la atención prestada

Atentamente,



**ANIBAL RAUL ACUAÑA MARTINEZ**  
CC. 77481627  
Médico Internista



## AVAL EXPERTO 2:

### Soporte de entrevista en video:

<https://drive.google.com/file/d/1qPUBDE5tqhIE-RTHZk8DVX7gHz2N05n/view?usp=sharing>



**AVAL DE PROYECTO POR UN EXPERTO MÉDICO**

Valledupar, 28 De agosto De 2025.

Señores:  
**COMITÉ DE INVESTIGACIÓN**  
Facultad de Ingenierías y Tecnológicas  
Programa de Ingeniería de Sistemas  
Universidad Popular Del Cesar

Cordial saludo

Yo **WISTON ALBERTO BAUTE REDONDO**, identificado con la cédula de ciudadanía No. 77006455 Y Cedula Profesional N.º 2432019, Como MEDICO y ESPECIALISTA EN CIRUJIA, con más de 35 años de experiencia certifico la VIABILIDAD Y FUNCIONALIDAD en el contexto clínico del aplicativo de proyecto de tesis como opción de grado para la universidad Popular del Cesar que lleva por título "AI-BONE X: APLICATIVO DE INTELIGENCIA ARTIFICIAL APOYADO EN EL MODELO CONVOLUCIONAL PARA EL DIAGNÓSTICO DE FRACTURAS EN EL CONTEXTO CLINICO DE LA CIUDAD DE VALLEDUPAR", presentada por los estudiantes de Ingeniería de Sistemas **WISTON ALBERTO BAUTE BAUTISTA** y **JUAN DAVID AYALA PRIMO**, así como la pertinencia del banco de datos utilizado en el mismo.

**Línea de investigación:** Transformación Digital

**Sublínea:** Inteligencia Artificial

Agradezco la atención prestada  
Atentamente,



**WISTON ALBERTO BAUTE REDONDO**  
CC 77006455  
Médico Cirujano  
UNIVERSIDAD NACIONAL AUTONOMA DE MEXICO



### 3.3 CONCLUSIONES

- ✓ El desarrollo y entrenamiento de la red neuronal convolucional (CNN) para la detección automática de fracturas permitió construir un prototipo funcional capaz de procesar imágenes radiológicas y ofrecer una predicción útil para apoyo al diagnóstico.
- ✓ Las etapas de: Preprocesamiento (normalización, alineación, aumento de datos), Selección de la arquitectura y técnicas de regularización, fueron determinantes para mejorar la estabilidad del entrenamiento y reducir el sobreajuste en conjuntos limitados.
- ✓ Los resultados experimentales muestran que el modelo identifica patrones radiológicos relevantes (patrón de discontinuidad cortical y patrón de trazo radiolúcido) con una precisión mayor al 70 %; sin embargo, su desempeño está íntimamente ligado a la calidad, cantidad y variedad de las imágenes que se ven involucradas en el entrenamiento.

### 3.4 RECOMENDACIONES

- ✓ Ampliar el dataset incluyendo imágenes de múltiples instituciones, equipos y grupos poblacionales; asegurar anotaciones por consenso entre al menos dos radiólogos para reducir ruido en las etiquetas.
- ✓ El proyecto aporta valor como prueba de concepto, base técnica para futuras investigaciones y despliegues clínicos, pero requiere validación prospectiva y colaboración interdisciplinaria (radiología, ingeniería clínica, regulatorio) antes de su adopción asistencial.
- ✓ Desde el punto de vista ético y regulatorio, el uso de datos de pacientes exige anonimización, consentimiento implícito/expreso según el caso y un plan claro de supervisión humana antes de cualquier uso clínico.

### 3.5 BIBLIOGRAFIA

[1] S. Russell and P. Norvig, *Artificial Intelligence: A Modern Approach*, 4th ed. Pearson, 2021.

[2] J. Sánchez-Monedero and L. Dencik, "The datafication of the workplace," Cardiff University, Working paper, 2019. [Online]. Available: <https://datajusticeproject.net/wp-content/uploads/sites/30/2019/05/Report-The-datafication-of-the-work-place.pdf>

[3] A. Celegghin, A. Borriero, D. Orsenigo, M. Diano, C. A. Méndez Guerrero, A. Perotti, G. Petri, and M. Tamietto, "Convolutional neural networks for vision neuroscience: significance, developments, and outstanding issues," *Frontiers in Computational Neuroscience*, vol. 17, Art. no. 1153572, 2023. doi: 10.3389/fncom.2023.1153572.

[4] M. Deeparani and M. Kalamani, "Gynecological healthcare: unveiling pelvic masses classification through evolutionary gravitational neocognitron neural network optimized with nomadic people optimizer," *Diagnostics*, vol. 13, no. 19, p. 3131, 2023. doi: 10.3390/diagnostics13193131.

[5] B. Koonce, "ResNet 50," in *Convolutional Neural Networks with Swift for Tensorflow*, Berkeley, CA: Apress, 2021, pp. [chapter section if available]. doi: 10.1007/978-1-4842-6168-2\_6.

[6] A. Llorens Montero, "Detección de fracturas en imágenes radiológicas con inteligencia artificial," 2024.

[7] L. S. Mejía Romero, "Inteligencia artificial y su uso en la radiografía," Bachelor's thesis, Universidad Técnica de Ambato, Facultad de Ciencias de Salud, Carrera de Medicina, 2024.

[8] J. Wu, N. Liu, X. Li, *et al.*, "Convolutional neural network for detecting rib fractures on chest radiographs: a feasibility study," *BMC Medical Imaging*, vol. 23, p. 18, 2023. [Online]. Available: <https://doi.org/10.1186/s12880-023-00975-x>

**[9]** J. A. Marín Rodríguez, "Inteligencia artificial en radiología," Bachelor's thesis, 2021.

**[10]** A. Castro and G. Manuel, "La inteligencia artificial en el análisis de imágenes radiológicas y el diagnóstico de enfermedades en el Hospital Juan Montalván del Cantón Urdaneta perteneciente a la Parroquia Ricaurte," Bachelor's thesis, Babahoyo: UTB-FAFI, 2023.

**[11]** C. A. R. López, J. G. I. Otoniel, G. M. Flores, and I. A. Cortes, "Implementación de una red neuronal convolucional para distinguir entre patrones radiológicos de COVID-19 y neumonía en imágenes tomográficas de tórax," *Ciencia Latina: Revista Multidisciplinar*, vol. 7, no. 6, p. 190, 2023.

**[12]** INSTITUTO NACIONAL DE MEDICINA LEGAL Y CIENCIAS FORENSES. Forensis 2016: datos para la vida [en línea]. Colombia: Medicina Legal; 2016. Disponible en: <https://www.medicinalegal.gov.co/documents/20143/49526/Forensis+2016.+Datos+para+la+vida.pdf>

**[13]** INSTITUTO NACIONAL DE MEDICINA LEGAL Y CIENCIAS FORENSES – INMLCF. *Forensis 2023: datos para la vida*. Bogotá: INMLCF, 2023. Disponible en: [https://www.medicinalegal.gov.co/documents/20143/1124000/Forensis\\_2023.pdf](https://www.medicinalegal.gov.co/documents/20143/1124000/Forensis_2023.pdf).

**[14]** TALO, Muhammed; YILDIRIM, Ozal; BALOGLU, Ulas Baran; AYDIN, Galip; ACHARYA, U. Rajendra. *Convolutional neural networks for multi-class brain disease detection using MRI images*. Computerized Medical Imaging and Graphics, [en línea]. 2019, vol. 78, p. 101673. ISSN 0895-6111. Disponible en: <https://doi.org/10.1016/j.compmedimag.2019.101673>

**[15]** LINDSEY, Ryan M.; et al. *Deep neural network improves fracture detection by clinicians*. PNAS, 2018. DOI: 10.1073/pnas.1806905115. Disponible en: <https://www.pnas.org/doi/10.1073/pnas.1806905115>

**[16]** DARTMOUTH COLLEGE. Dartmouth Summer Research Project on Artificial Intelligence. Hanover, Nueva Hampshire, EE. UU., 1956. Disponible en: <https://home.dartmouth.edu/about/artificial-intelligence-ai-coined-dartmouth>

**[17]** WEIZENBAUM, J. ELIZA: un programa de procesamiento de lenguaje natural. Massachusetts Institute of Technology (MIT), 1966. Disponible en: [https://www.academia.edu/3210729/ELIZA\\_a\\_computer\\_program\\_for\\_the\\_study\\_of\\_natural\\_language\\_communication\\_between\\_man\\_and\\_machine](https://www.academia.edu/3210729/ELIZA_a_computer_program_for_the_study_of_natural_language_communication_between_man_and_machine)

**[18]** HOPFIELD, J. J. Red de Hopfield: una red neuronal basada en principios físicos. 1982. Disponible en: [https://www.pnas.org/doi/pdf/10.1073/pnas.79.8.2554?utm\\_source=chatgpt.com](https://www.pnas.org/doi/pdf/10.1073/pnas.79.8.2554?utm_source=chatgpt.com)

**[19]** HOPFIELD, J., HINTON, G. Contribuciones fundamentales a redes neuronales artificiales y aprendizaje automático. The Guardian, 2024. Disponible en: [https://www.theguardian.com/science/2024/oct/08/nobel-prize-physics-john-hopfield-geoffrey-hinton-machine-learning?CMP=share\\_btn\\_url](https://www.theguardian.com/science/2024/oct/08/nobel-prize-physics-john-hopfield-geoffrey-hinton-machine-learning?CMP=share_btn_url).

**[20]** MIENYE, I. D., SWART, T. G., OBAIDO, G., JORDAN, M., ILONO, P. Deep convolutional neural networks in medical image analysis: A review. Information, 2025, 16(3): 195. Disponible en: <https://doi.org/10.3390/info16030195>

**[21]** LI, M., JIANG, Y., ZHANG, Y., ZHU, H. Medical image analysis using deep learning algorithms. Frontiers in Public Health, 2023, 11. Disponible en: <https://www.frontiersin.org/journals/public-health/articles/10.3389/fpubh.2023.1273253>

**[22]** CHEN, C., NOR ASHIDI MAT ISA, X., LIU, X. A review of convolutional neural network-based methods for medical image classification. Computers in Biology and Medicine, 2025, 185: 109507. Disponible en: <https://doi.org/10.1016/j.combiomed.2024.109507>

**Sección IV. Artículo Científico**

**AI-BONE X: APLICATIVO DE INTELIGENCIA ARTIFICIAL APOYADO EN EL MODELO CONVOLUCIONAL PARA EL DIAGNÓSTICO DE FRACTURAS EN EL CONTEXTO CLÍNICO DE LA CIUDAD DE VALLEDUPAR**

**DIRECTOR:**

TONNY JIMÉNEZ MÁRQUEZ

**INTEGRANTES:**

WISTON ALBERTO BAUTE BAUTISTA

CC1003316745

[wbaute@unicesar.edu.co](mailto:wbaute@unicesar.edu.co)

JUAN DAVID AYALA PRIMO

CC106583443

[jdayala@unicesar.edu.co](mailto:jdayala@unicesar.edu.co)



## 1. RESUMEN

La creciente demanda en los centros médicos en áreas de urgencias por accidentes de tránsito en motocicletas ha generado la necesidad de agilizar y optimizar la evaluación de imágenes radiológicas para la detección oportuna de fracturas, mucho de los médicos enfrentan limitaciones de tiempo para revisar grandes volúmenes de radiografías, al mismo tiempo no siempre está disponible para dar un diagnóstico el especialista lo que afecta la atención inmediata de los pacientes.

El desarrollo de una aplicación basada en inteligencia artificial basado redes neuronales convolucionales se ve respaldado por la creciente demanda de incorporar tecnologías avanzadas en el campo de la salud con el fin de mejorar la precisión y eficacia en los diagnósticos médicos, las fracturas son condiciones clínicas comunes que pueden llevar a complicaciones graves si no se detectan a tiempo, aumentando los gastos médicos y teniendo un impacto negativo en la calidad de vida de los pacientes. El objetivo de este proyecto es brindar una herramienta innovadora para ayudar al

personal médico en la evaluación automática de imágenes radiológicas, empleando marcos y bibliotecas robustas como TensorFlow, CV2 y Python.

## 2. ABSTRACT

The growing demand for emergency medical care due to motorcycle accidents in medical centers has generated the need to streamline and optimize the evaluation of radiological images for the timely detection of fractures. Many physicians face time constraints when reviewing large volumes of X-rays. At the same time, a specialist is not always available to provide a diagnosis, which impacts immediate patient care.

The development of an application based on artificial intelligence (AI) and convolutional neural networks is supported by the growing demand for incorporating advanced technologies in the healthcare field to improve the accuracy and effectiveness of medical diagnoses. Fractures are common clinical conditions that can lead to

serious complications if not detected early, increasing medical expenses and negatively impacting patients' quality of life. The objective of this project is to provide an innovative tool to assist medical personnel in the automatic evaluation of radiological images, using robust frameworks and libraries such as TensorFlow, CV2, and Python.

### 3. PALABRAS CLAVE

En este marco, se definen los conceptos clave utilizados en este proyecto:

- **Inteligencia Artificial (IA):** Campo de la informática que simula procesos de inteligencia humana a través de algoritmos y modelos matemáticos. En este caso, se utiliza para el diagnóstico médico mediante el análisis de imágenes.
- **Triage:** Es un sistema de selección y clasificación de pacientes en los servicios de urgencia, basado en sus necesidades terapéuticas y los recursos disponibles para atenderlo.
- **Iteración O Epoca:** Iteración significa repetir varias veces un proceso con la intención de alcanzar una meta deseada, objetivo o resultado.
- **Redes Neuronales Convolucionales (CNN):** Tipo de red neuronal diseñada para procesar datos visuales, especialmente utilizada en visión por computadora para tareas de clasificación y detección de objetos.
- **Diagnóstico de fracturas:** Proceso médico que implica la identificación de fracturas óseas a partir de imágenes, como radiografías, tomografías computarizadas o resonancias magnéticas.
- **Dataset:** Sistema donde la información se almacena en una estructura de directorios y carpetas, donde existen relaciones entre ellas para facilitar la organización, búsqueda y acceso a los datos.
- **Anonimización:** es el proceso de eliminar o modificar datos personales identificables para que no puedan asociarse con una persona en particular.

- **Diagnóstico de fracturas:** Proceso médico que implica la identificación de fracturas óseas a partir de imágenes, como radiografías, tomografías computarizadas o resonancias magnéticas.
- **Deep Learning (Aprendizaje Profundo):** Subcampo del aprendizaje automático que utiliza redes neuronales con múltiples capas para aprender representaciones de datos complejos.
- **Machine Learning:** Disciplina del campo de la Inteligencia Artificial que, a través de algoritmos, dota a los ordenadores de la capacidad de identificar patrones en datos grandes y elaborar predicciones.
- **TensorFlow:** Biblioteca open source (Código Abierto) desarrollada por Google para llevar a cabo tareas de Machine Learning y Deep Learning.
- **Clasificación de Imágenes:** Proceso mediante el cual se asigna una etiqueta o categoría a una imagen en función de su contenido visual.
- **Evaluación del Modelo:** Se refiere a la

medición del rendimiento del modelo desarrollado utilizando métricas como la precisión, sensibilidad, especificidad y el tiempo de respuesta.

#### 4. INTRODUCCIÓN

En la ciudad de Valledupar, el incremento en la demanda de los servicios de los centros médicos es notorio debido al número elevado de accidentes principalmente aquellos en los que se involucran vehículos según datos de medicina legal y publicados en su revista Forensis, esto genera la necesidad cada vez mayor en lo referente a la evaluación de imágenes radiológicas para el apoyo asistencial de los médicos de urgencias.

Por lo anterior surge la necesidad de crear una solución automatizada para asistir en la interpretación de dichas imágenes, especialmente en el área de urgencias, donde los especialistas no siempre están disponibles, facilitando así la labor de los médicos generales en el momento del triage.

En este contexto, la inteligencia artificial (IA) y en particular los modelos

convolucionales de redes neuronales (CNN) han demostrado ser herramientas eficaces para el análisis de imágenes médicas; por ello se plantea el desarrollo de un sistema basado en IA que pueda analizar automáticamente imágenes de rayos X para detectar la presencia de fracturas.

La innovación tecnológica en el campo de la tecnología médica va de la mano con nuevas máquinas que usan la inteligencia artificial como pilar fundamental ya que brinda como beneficio mejorar la calidad y la uniformidad de la imagen acelerando la recuperación o el diagnóstico previo de alguna enfermedad. [10]

## **5. OBJETIVOS**

### **5.1 OBJETIVO GENERAL**

Desarrollar y validar un aplicativo de inteligencia artificial basado en redes neuronales convolucionales (CNN) para asistir en el diagnóstico automatizado de fracturas óseas a partir de imágenes de rayos X de mano, codo y hombro en instituciones clínicas de la ciudad de Valledupar.

### **5.2 OBJETIVOS ESPECIFICOS**

- ✓ Analizar un conjunto de datos ajustados a las necesidades de la red neuronal.
- ✓ Preprocesar el conjunto de imágenes médicas por resolución, normalización y aumentación de datos por código que serán utilizadas para entrenar el modelo de la red neuronal convolucional
- ✓ Desarrollar el aplicativo de inteligencia artificial que integre el modelo de red neuronal convolucional para la detección de fracturas por parte de personal médico hasta lograr un estándar de precisión óptimo (Mayor al 70% de precisión basado en las métricas).
- ✓ Validar con datos clínicos el aplicativo de inteligencia artificial apoyado en el modelo de red neuronal convolucional con datos clínicos, evaluando la precisión, rendimiento y el

tiempo de respuesta del diagnóstico mediante las métricas de modelo accuracy y matriz de confusión.

- ✓ Presentar un prototipo funcional, verificado por personal médico, que integre el modelo entrenado y permita cargar imágenes para su análisis automático.

## 6. METODOLOGÍA Y METODOS DE VALIDACIÓN

Se considera que basado en los objetivos que se requieren alcanzar y la capacidad humana que hay para el desarrollo del proyecto se escoge la **Metodología XP**, la cual se soporta en los siguientes aspectos y fases de desarrollo

### 6.1 Justificación de la metodología XP

- Se eligió XP por ser una metodología ágil, adaptable y adecuada para equipos pequeños.

- Permite una rápida retroalimentación, desarrollo iterativo e integración continua, estas características son ideales para este proyecto que se caracteriza por un alto componente de experimentación como los de inteligencia artificial.
- En Inteligencia Artificial los resultados pueden cambiar según los datos o modelos, por lo que XP se ajusta bien al enfoque de prueba-error-control.

### 6.2 Métodos y Técnicas de Recolección e Interpretación de la Información

#### 6.2.1 Desarrollo experimental:

Se diseñará y entrenará una red neuronal convolucional, para integrarla en el aplicativo basado en el modelo convolucional CNN y ResNet50.

Se debe saber que una CNN se forma apilando las capas de entrada, convolución, agrupación,

completamente conectada y salida, la capa de entrada es la primera capa de una CNN, la entrada a una CNN consiste en imágenes sin procesar, que son vectores bidimensionales o tridimensionales, luego está la capa convolucional, que es el núcleo de una CNN, generalmente consiste en un conjunto de filtros o núcleos aprendibles con pequeños campos perceptuales. [8]

Por otra parte, ResNet 50 como una red convolucional especializada es entrenada con el conjunto de datos del proyecto y se modifican las últimas capas (lo que se denomina reentrenamiento o aprendizaje por transferencia), se utiliza para lograr resultados óptimos, este es el mejor enfoque para empezar, en lugar de intentar inventar nuevas redes o técnicas es mejor crear un conjunto de datos personalizado y escalarlo con técnicas de aumentación de datos.[5]

De la misma manera, cabe aclarar que gracias al artículo científico publicado de la revista “Computerized Medical Imaging and Graphics (Vol. 78)” demostró que Resnet50 comparada con las demás como (AlexNet, Vgg-16, Resnet-18 y Resnet-34) obtuvo mejores resultados en el ámbito de la medicina para el análisis de imágenes y detección de anomalías en resonancias magnéticas y similares como lo son las de rayos x.[14]


**6.2.2 Validación empírica:** Se evaluará la precisión y efectividad del entrenamiento.

**6.2.3 Validación en métricas:** Se evaluará la precisión y efectividad del entrenamiento con los resultados de las métricas como lo son el Modelo Accuracy y La Matriz de confusión.


**6.2.4 Recolección de datos:** Se obtuvieron un conjunto de imágenes médicas apropiadas y disponibles en un dataset de KAGGLE en internet, que

limpamos y validamos su usabilidad mediante el siguiente fragmento de código:

KAGGLE que es una fuente confiable que permite utilizar Dataset específicos para hacer entrenamiento de redes neuronales, se escogió MURA V11 debido a sus constantes aportes de la comunidad a su mejoramiento y cantidad de imágenes que nos proporciona



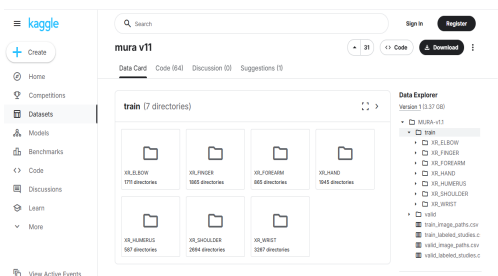
objetivo la validación de los resultados del entrenamiento que tiene numerosas subcarpetas de información



También se utiliza las siguientes fuentes de información para aportar resultados:

- Algoritmos de preprocesamiento y análisis (Python, librerías como OpenCV, TensorFlow/Keras).
- Registro de métricas (Matplotlib) durante el entrenamiento y prueba del modelo.

Se utilizan dos carpetas, una para entrenar llamada TRAIN



La otra es VALID que tiene como

**6.2.5 Preprocesamiento de imágenes:** Las imágenes serán normalizadas, aplicando técnicas

de procesamiento de imágenes como escalado, aumentación de datos por código

### 6.2.6 Pruebas de Profesionales:

Se llevarán a cabo validaciones de médicos expertos que nos darán sus opiniones al respecto.

### 6.2.7 Población:

20.335 imágenes de rx de pacientes desconocidos de un banco de datos de uso libre de KAGGLE aprobado su viabilidad y pertinencia por nuestro personal médico.

### 6.2.8 Muestra:

20.322 imágenes de mano, hombro y codo resultado del preprocesamiento y normalización del dataset anteriormente mencionado.

## 6.3 FASES PLANTEADAS



### 6.3.1 PLANIFICACIÓN

#### REQUISITOS FUNCIONALES:

Se busca definir funcionalidades (historias de usuario) y priorizarlas según valor y complejidad.

#### REQ. NO FUNCIONALES:

Diagnóstico del funcionamiento del aplicativo arrojando el primer resultado general:




### 6.3.2 DISEÑO:

Se documentaron los casos de uso

### ARQUITECTURA DE ALTO NIVEL:

Se utilizó python para la codificación y entrenamiento del modelo con el apoyo de las siguientes librerías en sus diferentes versiones:

- customtkinter~=5.0.3
- PyAutoGUI~=0.9.53
- PyGetWindow~=0.0.9
- Pillow~=8.4.0
- numpy~=1.19.5
- tensorflow~=2.6.2
- keras~=2.6.0
- pandas~=1.1.5
- matplotlib~=3.3.4
- scikit-learn~=0.24.2
- colorama~=0.4.5
- pyside6



### 6.3.3 CODIFICACIÓN:

Basado en la metodología propuesta se organizaban sesiones compartidas donde uno programaba y el otro revisaba en tiempo real.

En momentos de trabajo individual, se revisaba luego en conjunto con control de versiones, se deja plasmado el avance del proyecto en los diferentes commits en el siguiente repositorio de GITHUB:

<https://github.com/juadadev/Fraturas-app>

```
Bone-Fracture-Detection
├── .git
├── .venv
├── Dataset
├── PredictResults
├── __pycache__
├── app
├── auth
├── images
├── plots
├── test
├── weights
├── .gitignore
├── README.md
├── main.py
├── main2.py
├── mainGUI.py
├── prediction_test.py
├── predictions.py
├── pyrightconfig.json
├── requirements.txt
├── training_fracture.py
├── training_parts.py
```

### 6.3.4 PRUEBAS

Se realizan pruebas unitarias y de integración para verificar la funcionalidad del aplicativo, todas estas mediante código

#### Pruebas Unitarias:

- 1) En test\_predict.py, se prueba que la lógica de predicción clasifique correctamente una imagen como "Hombro" y "Fracturado", validando que los cálculos sean correctos.
- 2) test\_main\_content\_widget.py, prueba que el botón "Generar Reporte PDF" cree un archivo válido con los datos del paciente y el resultado del diagnóstico.

#### Pruebas De Integración:

- 1) test\_login\_controller.py, simula un inicio de sesión para asegurar que la vista (UI), el controlador (lógica) y el autenticador se

comunican bien para validar o rechazar a un usuario,

### 6.3.5 IMPLEMENTACIÓN



## 7. ANÁLISIS DE RESULTADOS Y DISCUSIÓN.

En relación con los objetivos planteados para el desarrollo del proyecto de detección de fracturas mediante inteligencia artificial, los resultados esperados son los siguientes:

### 7.1 Recolección del conjunto de imágenes:

Se recolectó un extenso conjunto de imágenes de rayos X de mano, codo y hombro, se llevó a cabo mediante la exploración y

descarga de múltiples imágenes de un dataset público disponible en internet para fines educativos, siendo la plataforma Kaggle una fuente primordial para nuestra recolección de datos.

De la misma manera la agregación de datos provenientes de diversos aportes de la comunidad al dataset permitió construir un conjunto robusto de imágenes considerablemente amplio para el entrenamiento efectivo de un modelo de inteligencia artificial capaz de cumplir con los objetivos de detección

## **7.2 Dificultades durante la recolección:**

En el proceso de recopilación dichas imágenes desde diversas fuentes en línea se identificaron los siguientes desafíos:

- **Variedad en Formatos y Calidad:** La inconsistencia en los formatos de archivo y la calidad de las imágenes entre diferentes

carpetas dificultaba su integración, por lo que se unificaron formatos y se aplicaron criterios de selección por código para descargar imágenes con errores o dañadas, al mismo tiempo se estableció un fragmento de código que normaliza todas las imágenes a 224 píxeles.

- **Desbalance de Datos:** Algunas carpetas presentaban una proporción desigual entre imágenes con y sin fractura, esto podía afectar el rendimiento del modelo, por lo que se aumentaron el número de registros en la clase minoritaria (imágenes con fracturas) para así lograr equilibrar el conjunto de entrenamiento.

## **7.4 Preparación del conjunto de datos:**

Se logró realizar un análisis exhaustivo del conjunto de datos médicos seleccionados, todo esto con el fin de garantizar que estos cumplieran con los requisitos de

calidad, relevancia y representatividad necesarios para el entrenamiento efectivo de la red neuronal

Se crean 3 carpetas respectivamente para cada tipo de radiografía

- ✓ **MANO**
- ✓ **HOMBRO**
- ✓ **CODO**

### 7.5 Validación del aplicativo con datos clínicos


El aplicativo fue validado utilizando un conjunto independiente de datos clínicos reales aprobados por nuestro asesor, los resultados demostraron que el modelo alcanzó un alto nivel de precisión en la detección de fracturas, con tiempos de respuesta adecuados.

#### ✓ **METRICA 1:**

DURANTE LOS  
ENTRENAMIENTOS SE  
SACARON GRAFICAS Y

### RESULTADOS OBTENIDOS EN DONDE SE DEMUESTRA:

- La precisión en entrenamiento aumenta progresivamente de ~0.69 en la época 1 hasta ~0.82 en la época 19.
- La validación también mejora desde ~0.72 hasta estabilizarse entre 0.77 y 0.80, aunque con fluctuaciones.
- En la época 15, la precisión en entrenamiento sigue llega a su pico más alto (hasta 82%), por lo que se escogen esos pesos para el modelo.



El aplicativo arroja resultados positivos, basados en el modelo que se entrenó previamente

✓ **METRICA 2:**

**MATRIZ DE CONFUSIÓN:**

```
Hand Results:
[0.4717140197753906, 0.7853577136993408]
Test Accuracy: 78.54%
Confusion Matrix:
[[ 83  99]
 [ 30 389]]
Classification Report:
      precision    recall  f1-score   support

     0       0.73     0.46     0.56       182
     1       0.80     0.93     0.86       419

 accuracy         0.79       601
 macro avg       0.77     0.69     0.71       601
 weighted avg    0.78     0.79     0.77       601

Found 6434 validated image filenames belonging to 2 classes.
Found 1608 validated image filenames belonging to 2 classes.
Found 894 validated image filenames belonging to 2 classes.
```

[0.4717140197753906,  
0.7853577136993408]

El primer valor corresponde a la pérdida (loss) y precisión (accuracy) del modelo en entrenamiento o evaluación.

El valor 0.7853  $\approx$  78.54% indica la precisión global del modelo en el conjunto de prueba.

Test Accuracy: 78.54%  
(Porcentaje de Aciertos)

El modelo acertó en aproximadamente 79 de cada 100 imágenes.

```
Hand Results:
[0.4717140197753906, 0.7853577136993408]
Test Accuracy: 78.54%
Confusion Matrix:
[[ 83  99]
 [ 30 389]]
```

Esto indica cómo el modelo clasificó las imágenes en dos clases:

0: Sin fractura 1: Con fractura

Predijo 0 (Sin fractura) Predijo 1 (Con fractura)  
Era 0 (sin fractura) 83 (✓) 99 (✗ Falsos positivos)  
Era 1 (con fractura) 30 (✗ Falsos negativos) 389 (✓)

**7.6 Validación del aplicativo por expertos médicos**

**AVAL EXPERTO 1:**

Soporte de entrevista en video:

<https://drive.google.com/file/d/1pv6mRvigLqBZotYSldZqvSaE8xLPySzW/view?usp=sharing>

**AVAL EXPERTO 2:**

Soporte de entrevista en video:

<https://drive.google.com/file/d/1qPUbDE5tqhIE-RTHZk-8DVX7gHz2N05n/view?usp=drive link>

## 8. CONCLUSIONES

- ✓ El desarrollo y entrenamiento de la red neuronal convolucional (CNN) para la detección automática de fracturas permitió construir un prototipo funcional capaz de procesar imágenes radiológicas y ofrecer una predicción útil para apoyo al diagnóstico.
- ✓ Las etapas de: Preprocesamiento (normalización, alineación, aumento de datos), Selección de la arquitectura y técnicas de regularización, fueron determinantes para mejorar la estabilidad del entrenamiento y reducir el sobreajuste en conjuntos limitados.
- ✓ Los resultados experimentales muestran que el modelo identifica patrones radiológicos relevantes (patrón de discontinuidad cortical y patrón de trazo radiolúcido) con una precisión mayor al 70 %; sin embargo, su desempeño está íntimamente ligado a la calidad, cantidad y variedad de las

imágenes que se ven involucradas en el entrenamiento.

## 9. RECOMENDACIONES

- ✓ Ampliar el dataset incluyendo imágenes de múltiples instituciones, equipos y grupos poblacionales; asegurar anotaciones por consenso entre al menos dos radiólogos para reducir ruido en las etiquetas.
- ✓ El proyecto aporta valor como prueba de concepto, base técnica para futuras investigaciones y despliegues clínicos, pero requiere validación prospectiva y colaboración interdisciplinaria (radiología, ingeniería clínica, regulatorio) antes de su adopción asistencial.
- ✓ Desde el punto de vista ético y regulatorio, el uso de datos de pacientes exige anonimización, consentimiento implícito/expreso según el caso y un plan claro de supervisión humana antes de cualquier uso clínico.

## 10. REFERENCIAS

[1] S. Russell and P. Norvig, *Artificial Intelligence: A Modern Approach*, 4th ed. Pearson, 2021.

[2] J. Sánchez-Monedero and L. Dencik, "The datafication of the workplace," Cardiff University, Working paper, 2019. [Online]. Available: <https://datajusticeproject.net/wp-content/uploads/sites/30/2019/05/Report-The-datafication-of-the-work-place.pdf>

[3] A. Celeghin, A. Borriero, D. Orsenigo, M. Diano, C. A. Méndez Guerrero, A. Perotti, G. Petri, and M. Tamietto, "Convolutional neural networks for vision neuroscience: significance, developments, and outstanding issues," *Frontiers in Computational Neuroscience*, vol. 17, Art. no. 1153572, 2023. doi: 10.3389/fncom.2023.1153572.

[4] M. Deeparani and M. Kalamani, "Gynecological healthcare: unveiling pelvic

masses classification through evolutionary gravitational neocognitron neural network optimized with nomadic people optimizer," *Diagnostics*, vol. 13, no. 19, p. 3131, 2023. doi: 10.3390/diagnostics13193131.

[5] B. Koonce, "ResNet 50," in *Convolutional Neural Networks with Swift for Tensorflow*, Berkeley, CA: Apress, 2021, pp. [chapter section if available]. doi: 10.1007/978-1-4842-6168-2\_6.

[6] A. Llorens Montero, "Detección de fracturas en imágenes radiológicas con inteligencia artificial," 2024.

[7] L. S. Mejía Romero, "Inteligencia artificial y su uso en la radiografía," Bachelor's thesis, Universidad Técnica de Ambato, Facultad de Ciencias de Salud, Carrera de Medicina, 2024.

[8] J. Wu, N. Liu, X. Li, *et al.*, "Convolutional neural network for detecting rib fractures on chest radiographs: a feasibility study," *BMC Medical Imaging*, vol. 23, p. 18, 2023. [Online]. Available:

<https://doi.org/10.1186/s12880-023-00975-x>

**[9]** J. A. Marín Rodríguez, "Inteligencia artificial en radiología," Bachelor's thesis, 2021.

**[10]** A. Castro and G. Manuel, "La inteligencia artificial en el análisis de imágenes radiológicas y el diagnóstico de enfermedades en el Hospital Juan Montalván del Cantón Urdaneta perteneciente a la Parroquia Ricaurte," Bachelor's thesis, Babahoyo: UTB-FAFI, 2023.

**[11]** C. A. R. López, J. G. I. Otoniel, G. M. Flores, and I. A. Cortes, "Implementación de una red neuronal convolucional para distinguir entre patrones radiológicos de COVID-19 y neumonía en imágenes tomográficas de tórax," *Ciencia Latina: Revista Multidisciplinar*, vol. 7, no. 6, p. 190, 2023.

**[12]** INSTITUTO NACIONAL DE MEDICINA LEGAL Y CIENCIAS FORENSES. *Forensis 2016: datos para la vida* [en línea]. Colombia: Medicina Legal; 2016. Disponible en: <https://www.medicinalegal.gov.co/doc>

[uments/20143/49526/Forensis+2016.+Datos+para+la+vida.pdf](https://www.medicinalegal.gov.co/doc/uments/20143/49526/Forensis+2016.+Datos+para+la+vida.pdf)

**[13]** INSTITUTO NACIONAL DE MEDICINA LEGAL Y CIENCIAS FORENSES – INMLCF. *Forensis 2023: datos para la vida*. Bogotá: INMLCF, 2023. Disponible en: [https://www.medicinalegal.gov.co/doc/uments/20143/1124000/Forensis\\_2023.pdf](https://www.medicinalegal.gov.co/doc/uments/20143/1124000/Forensis_2023.pdf).

**[14]** TALO, Muhammed; YILDIRIM, Ozal; BALOGLU, Ulas Baran; AYDIN, Galip; ACHARYA, U. Rajendra. *Convolutional neural networks for multi-class brain disease detection using MRI images*. *Computerized Medical Imaging and Graphics*, [en línea]. 2019, vol. 78, p. 101673. ISSN 0895-6111. Disponible en: <https://doi.org/10.1016/j.compmedimag.2019.101673>

**[15]** LINDSEY, Ryan M.; et al. *Deep neural network improves fracture detection by clinicians*. *PNAS*, 2018. DOI: 10.1073/pnas.1806905115. Disponible en: <https://www.pnas.org/doi/10.1073/pnas.1806905115>

**[16]** DARTMOUTH COLLEGE. Dartmouth Summer Research Project on Artificial Intelligence. Hanover, Nueva Hampshire, EE.UU., 1956. Disponible en: <https://home.dartmouth.edu/about/artificial-intelligence-ai-coined-dartmouth>

**[17]** WEIZENBAUM, J. ELIZA: un programa de procesamiento de lenguaje natural. Massachusetts Institute of Technology (MIT), 1966. Disponible en: [https://www.academia.edu/3210729/ELIZA\\_a\\_computer\\_program\\_for\\_the\\_study\\_of\\_natural\\_language\\_communication\\_between\\_man\\_and\\_machine](https://www.academia.edu/3210729/ELIZA_a_computer_program_for_the_study_of_natural_language_communication_between_man_and_machine)

**[18]** HOPFIELD, J. J. Red de Hopfield: una red neuronal basada en principios físicos. 1982. Disponible en: [https://www.pnas.org/doi/pdf/10.1073/pnas.79.8.2554?utm\\_source=chatgpt.com](https://www.pnas.org/doi/pdf/10.1073/pnas.79.8.2554?utm_source=chatgpt.com)

**[19]** HOPFIELD, J., HINTON, G. Contribuciones fundamentales a redes neuronales artificiales y aprendizaje automático. The Guardian, 2024. Disponible en:

[https://www.theguardian.com/science/2024/oct/08/nobel-prize-physics-john-hopfield-geoffrey-hinton-machine-learning?CMP=share\\_btn\\_url](https://www.theguardian.com/science/2024/oct/08/nobel-prize-physics-john-hopfield-geoffrey-hinton-machine-learning?CMP=share_btn_url).

**[20]** MIENYE, I. D., SWART, T. G., OBAIDO, G., JORDAN, M., ILONO, P. Deep convolutional neural networks in medical image analysis: A review. Information, 2025, 16(3): 195. Disponible en: <https://doi.org/10.3390/info16030195>

**[21]** LI, M., JIANG, Y., ZHANG, Y., ZHU, H. Medical image analysis using deep learning algorithms. Frontiers in Public Health, 2023, 11. Disponible en: <https://www.frontiersin.org/journals/public-health/articles/10.3389/fpubh.2023.1273253>

**[22]** CHEN, C., NOR ASHIDI MAT ISA, X., LIU, X. A review of convolutional neural network-based methods for medical image classification. Computers in Biology and Medicine, 2025, 185: 109507

**Anexo A.** Carta del director del proyecto

Valledupar, 10 de septiembre de 2025.

Señores:  
COMITÉ DE INVESTIGACIÓN  
Facultad de Ingenierías y Tecnológicas  
Programa de Ingeniería de Sistemas  
Universidad Popular Del Cesar


Cordial saludo

Yo **TONNY JIMENEZ MARQUEZ**, identificado con la cédula de ciudadanía No. **77188569**, certifico que he revisado el documento correspondiente al proyecto final que lleva por título **“AI-BONE X: APLICATIVO DE INTELIGENCIA ARTIFICIAL APOYADO EN EL MODELO CONVOLUCIONAL PARA EL DIAGNÓSTICO DE FRACTURAS EN EL CONTEXTO CLÍNICO DE LA CIUDAD DE VALLEDUPAR”**, presentado por los estudiantes **WISTON ALBERTO BAUTE BAUTISTA** y **JUAN DAVID AYALA PRIMO**, y, después de haberle realizado las respectivas correcciones, cuenta con mi aprobación para ser presentada ante el comité. Sugiero la aprobación por parte de ustedes. (Soporte: Anexo 1)

**Línea de investigación:** Transformación Digital

**Sublínea:** Inteligencia Artificial

Atentamente,



**TONNY JIMENEZ MARQUEZ**  
CC 77188569  
Director de Proyecto

## ANEXO 1:

The image shows a split-screen view. On the left is a Microsoft Teams video conference window titled 'REVISIÓN FINAL TESIS DE GRADO'. It shows three participants: WISTÓN ALBERTO BAUTE BAUTISTA, JUAN DAVID AYALA PRIMO, and Tony (No comprobado). The top bar indicates the meeting time as 02:48:22 and includes controls for participation, camera, microphone, and chat. On the right is a Microsoft Word document window titled 'PROYECT...'. The document is in 'Solo lectura' (Read-only) mode, as indicated by a yellow banner. The document content is as follows:

**SECCIÓN I: DESCRIPCIÓN GENERAL**

**1.1.- TÍTULO DEL PROYECTO**  
APLICATIVO DE INTELIGENCIA ARTIFICIAL APOYADO EN EL MODELO CONVOLUCIONAL PARA EL DIAGNÓSTICO DE FRACTURAS EN EL CONTEXTO CLÍNICO DE LA CIUDAD DE VALLEDUPAR

**1.2.- DIRECCIÓN DE EJECUCIÓN DEL PROYECTO**  
La aclaración del lugar de ejecución se encuentre en el (ANEXO C)

**1.3.- LAPSO DE EJECUCIÓN DEL PROYECTO**  
6 meses de duración  
Del 12 de agosto del 2024 al 12 de enero de 2025

**1.4.- ORGANISMO Y SECCIÓN RESPONSABLE**  
Dicho proyecto será un prototipo experimental de una IA para la detección de fracturas que se aplicará al sector salud si la universidad nos hace las respectivas gestiones debido a las imposibilidades propias que nosotros como estudiantes tuvimos que se justifica en el (ANEXO C), sin embargo, es revisado y aprobada su efectividad por profesionales médicos expertos (ANEXO C1 y ANEXO C2)

**1.5.- INFORMACIÓN DE CONTACTO DE LOS ESTUDIANTES**

The bottom of the Word window shows a status bar with 'Página 52 de 60', '8805 palabras', and a table with columns for 'Nombre', 'Apellido', 'Cedula', 'Telefono', and 'Correo'. The Windows taskbar at the bottom shows the date and time as 9:04 p. m. on 10/09/2025.

### Soporte De Video:

[https://unicesareduco-my.sharepoint.com/:v/g/personal/wbaute\\_unicesar\\_edu\\_co/ETuTNnefu8dEtELwSv7yqPMBSkmjp4GIchWmqyjrN091IQ?e=pMNJiP](https://unicesareduco-my.sharepoint.com/:v/g/personal/wbaute_unicesar_edu_co/ETuTNnefu8dEtELwSv7yqPMBSkmjp4GIchWmqyjrN091IQ?e=pMNJiP)

**Anexo B. Carta de los estudiantes**

Valledupar, 10 De septiembre de 2025.

Señores:  
COMITÉ DE INVESTIGACIÓN  
Facultad de Ingenierías y Tecnológicas  
Programa de Ingeniería de Sistemas  
Universidad Popular Del Cesar

Cordial saludo

Nosotros los abajo firmantes, estudiantes del programa de Ingeniería de sistemas, presentamos a ustedes el documento correspondiente al proyecto de grado denominado **“AI-BONE X: APLICATIVO DE INTELIGENCIA ARTIFICIAL APOYADO EN EL MODELO CONVOLUCIONAL PARA EL DIAGNÓSTICO DE FRACTURAS EN EL CONTEXTO CLÍNICO DE LA CIUDAD DE VALLEDUPAR”**.

Quedamos a la espera del concepto emitido por el comité respecto de la viabilidad y aceptación de dicha propuesta.


Agradecemos la atención prestada

Atentamente,



WISTON ALBERTO BAUTE BAUTISTA

CC. 1003316745 de Valledupar



JUAN DAVID AYALA PRIMO

CC. 1065834443 de Valledupar

08 De septiembre De 2025

## **CERTIFICA**

Que los estudiantes Wiston Alberto Baute Bautista identificado con CC 1003316745 y a Juan David Ayala Primo con CC 1065834443, los dos estudiantes de Ingeniería de sistemas de la Universidad Popular Del Cesar quienes tienen el proyecto como opción de grado que llevan a cabo llamado **“AI-BONE X: APLICATIVO DE INTELIGENCIA ARTIFICIAL APOYADO EN EL MODELO CONVOLUCIONAL PARA EL DIAGNÓSTICO DE FRACTURAS EN EL CONTEXTO CLÍNICO DE LA CIUDAD DE VALLEDUPAR”** que se encuentra la propuesta y anteproyecto aprobado por el consejo

### **SE AUTORIZAN:**

Para presentar el PROYECTO FINAL sin aval de una empresa o entidad y sin un lugar específico de ejecución debido a que la IA fue entrenada con más de 20 mil imágenes de un dataset de fuentes externas confiables que fue verificado por nuestro asesor y nos arrojó resultados de más del 75% de asertividad, logrando un factor de éxito óptimo.

Sin embargo, la aplicación es APROBADA por personal médico especializado que certifican la funcionalidad y el beneficio de su usabilidad en el contexto clínico de urgencias en la ciudad de Valledupar (ANEXOC1 y ANEXOC2)

### **DEBIDO A:**

Que nos acercamos a las diferentes entidades de salud públicas y privadas de la ciudad en Valledupar que cuentan con urgencias en varias ocasiones, a la cual recibimos negativa del proyecto debido a que el mismo involucra IA y ellos lo consideran como “experimental”, por lo que recurrimos a médicos expertos que laboran en el área de urgencias para recibir su correspondiente aval, de los cuales recibimos respuestas positivas

Dicha autorización es aprobada por nuestro departamento de ingeniería de sistemas, nuestro director de programa el Ingeniero ALVARO OÑATE BOWEN y nuestro asesor de proyecto el Ingeniero TONNY JIMÉNEZ MÁRQUEZ, quién firma este documento para mayor constancia



INGENIERO TONNY JIMÉNEZ MÁRQUEZ

Asesor De Proyecto- Docente

## AVAL DE PROYECTO POR UN EXPERTO MÈDICO

Valledupar, 31 De agosto De 2025.

Señores:

**COMITÉ DE INVESTIGACIÓN**  
Facultad de Ingenierías y Tecnológicas  
Programa de Ingeniería de Sistemas  
Universidad Popular Del Cesar


Cordial saludo

Yo **ANIBAL RAUL ACUÑA MARTINEZ**, identificado con la cédula de ciudadanía No. 77181627, Como MÉDICO PROFESIONAL y ESPECIALISTA EN MÉDICA INTERNA certifico la VIABILIDAD Y FUNCIONALIDAD en el contexto clínico del aplicativo de proyecto de tesis como opción de grado para la universidad Popular del Cesar que lleva por título “**AI-BONE X: APLICATIVO DE INTELIGENCIA ARTIFICIAL APOYADO EN EL MODELO CONVOLUCIONAL PARA EL DIAGNÓSTICO DE FRACTURAS EN EL CONTEXTO CLÍNICO DE LA CIUDAD DE VALLEDUPAR**”, presentada por los estudiantes de Ingeniería de Sistemas **WISTON ALBERTO BAUTE BAUTISTA** y **JUAN DAVID AYALA PRIMO**, así como la pertinencia del banco de datos utilizado por el mismo

Línea de investigación: Transformación Digital

Sublínea: Inteligencia Artificial

Atentamente,

  
**ANIBAL RAUL ACUÑA MARTINEZ**  
CC 77181627  
Médico Internista

**AVAL DE PROYECTO POR UN EXPERTO MÈDICO**

Valledupar, 28 De agosto De 2025.

Señores:  
COMITÉ DE INVESTIGACIÓN  
Facultad de Ingenierías y Tecnológicas  
Programa de Ingeniería de Sistemas  
Universidad Popular Del Cesar

Cordial saludo

Yo **WISTON ALBERTO BAUTE REDONDO**, identificado con la cédula de ciudadanía No. 77006455 Y Cedula Profesional N° 2432019, Como MÉDICO y ESPECIALISTA EN CIRUGIA, con más de 35 años de experiencia certifico la VIABILIDAD Y FUNCIONALIDAD en el contexto clínico del aplicativo de proyecto de tesis como opción de grado para la universidad Popular del Cesar que lleva por título “**AI-BONE X: APLICATIVO DE INTELIGENCIA ARTIFICIAL APOYADO EN EL MODELO CONVOLUCIONAL PARA EL DIAGNÓSTICO DE FRACTURAS EN EL CONTEXTO CLÍNICO DE LA CIUDAD DE VALLEDUPAR**”, presentada por los estudiantes de Ingeniería de Sistemas **WISTON ALBERTO BAUTE BAUTISTA** y **JUAN DAVID AYALA PRIMO**, así como la pertinencia del banco de datos utilizado en el mismo.

Atentamente,



WISTON ALBERTO BAUTE REDONDO  
CC 77006455  
Médico Cirujano  
UNIVERSIDAD NACIONAL AUTONOMA DE MÉXICO

**ANEXO D**

# **MANUAL DE USUARIO**

**(AI-BONE X: APLICATIVO DE INTELIGENCIA ARTIFICIAL APOYADO EN EL MODELO CONVOLUCIONAL PARA EL DIAGNÓSTICO DE FRACTURAS EN EL CONTEXTO CLÍNICO DE LA CIUDAD DE VALLEDUPAR)**

**DIRECTOR DE PROYECTO:**

**TONNY JIMÉNEZ MÁRQUEZ**

**INTEGRANTES:**

**WISTON ALBERTO BAUTE BAUTISTA**

**CC1003316745**

**[wbaute@unicesar.edu.co](mailto:wbaute@unicesar.edu.co)**

**JUAN DAVID AYALA PRIMO**


**CC106583443**

**[jdayala@unicesar.edu.co](mailto:jdayala@unicesar.edu.co)**


### **OBSERVACIONES IMPORTANTES**


Debido a que el aplicativo fue diseñado para ser intuitivo y fácil de usar se optó por un paso a paso lineal que permita que el usuario logre sentir que el aplicativo tiene un patrón poco complicado para que cualquier persona pueda usarlo

## INGRESO DE USUARIO (INTERFAZ EXTERNA)



## INTERFAZ INTERNA DEL APLICATIVO





informe\_fractura\_20250905\_212648.pdf — Okular

File View Edit Go Bookmarks Tools Settings Help


45.3% View Mode 1 of 2 Browse AI Text Selection Yellow Highlighter

**Informe de Detección de Fractura Ósea**

**Datos del Paciente:**  
Tipo de Documento: C.C  
Número de Documento: 1065834056  
Nombre: LUIS CAMILO  
Apellido: ROJAS


**Resultados del Análisis:**  
Resultado: Fracturado (confianza 79.9%)  
Tipo: Hand (confianza 100.0%)  
Riesgo: Medio (score=0.70)  
Prioridad: Atención prioritaria

Imagen analizada con anotaciones:



Fecha del análisis: 2025-09-05 21:26:51

**PASO 8: Se puede utilizar el informe como diagnostico preliminar en la atención de urgencias médicas en traumatismos relacionados con el hombro, mano y codo**



## ANEXO F: RESULTADOS TURNITIN



### Recibo digital

Este recibo confirma que su trabajo ha sido recibido por Turnitin. A continuación podrá ver la información del recibo con respecto a su entrega.

La primera página de tus entregas se muestra abajo.

Autor de la entrega: WISTON ALBERTO BAUTE BAUTISTA  
Título del ejercicio: TURNITIN Parte 2 (Moodle TT)  
Título de la entrega: PROYECTO-ENTREGA-FINAL-WB-JA  
Nombre del archivo: 40966\_WISTON\_ALBERTO\_BAUTE\_BAUTISTA\_PROYECTO-ENTR...  
Tamaño del archivo: 3.78M  
Total páginas: 91  
Total de palabras: 12,134  
Total de caracteres: 67,756  
Fecha de entrega: 09-oct-2025 01:58a. m. (UTC-0500)  
Identificador de la entrega: 2775682584



Derechos de autor 2025 Turnitin. Todos los derechos reservados.



PROYECTO DE GRADO

AI-BONE X: APLICATIVO DE INTELIGENCIA ARTIFICIAL APOYADO  
EN EL MODELO CONVOLUCIONAL PARA EL DIAGNÓSTICO DE  
FRACTURAS EN EL CONTEXTO CLÍNICO DE LA CIUDAD DE  
VALLEDUPAR

DIRECTOR:  
TONNY JIMÉNEZ MÁRQUEZ

Resumen de coincidencias

17 %

1	Entregado a Universida... Trabajo del estudiante	2 %
2	Entregado a Corporaci... Trabajo del estudiante	1 %
3	dspace.utb.edu.ec Fuente de Internet	1 %
4	www.coursehero.com Fuente de Internet	1 %
5	github.com Fuente de Internet	1 %
6	editorialalema.org Fuente de Internet	1 %
7	Tapia Catacora, Pablo ... Publicación	1 %