



**UNIVERSIDAD ESTATAL PENÍNSULA
DE SANTA ELENA
FACULTAD DE SISTEMAS Y TELECOMUNICACIONES
INSTITUTO DE POSTGRADO**

TITULO DEL TRABAJO DE TITULACIÓN

**MODELO BASADO EN VISIÓN POR COMPUTADOR PARA LA
PREDICCIÓN DE OSTEOARTRITIS EN IMÁGENES DE RAYOS X.**

AUTOR

Tomalá Guaranda, Andrés Darío

TRABAJO DE TITULACIÓN

**Previo a la obtención del grado académico en
MAGISTER EN TECNOLOGÍAS DE LA INFORMACIÓN**

TUTOR

Andrade Vera, Alicia.

Santa Elena, Ecuador

Año 2024



**UNIVERSIDAD ESTATAL PENÍNSULA
DE SANTA ELENA
FACULTAD DE SISTEMAS Y TELECOMUNICACIONES
INSTITUTO DE POSTGRADO
TRIBUNAL DE SUSTENTACIÓN**

**Ing. Marcia Bayas Sampedor, Ph. D
COORDINADORA DEL
PROGRAMA**



Firmado electrónicamente por:
ALBERT GIOVANNY
ESPINAL SANTANA

**Ing. Alicia Andrade Vera, Mgtr
TUTOR**

**Ing. Albert Espinal Santana, Ph D
DOCENTE
ESPECIALISTA**

**Ing. Byron Bayas Oviedo, Ph. D
DOCENTE
ESPECIALISTA**

**Abg. María Rivera, Mgtr
SECRETARIO GENERAL
UPSE**



**UNIVERSIDAD ESTATAL PENÍNSULA
DE SANTA ELENA
FACULTAD DE SISTEMAS Y TELECOMUNICACIONES
INSTITUTO DE POSTGRADO**

CERTIFICACIÓN

Certifico que, tras dirigir científica y técnicamente el desarrollo y estructura final del trabajo, este cumple y se ajusta a los estándares académicos, por eso apruebo en todas sus partes el trabajo de titulación realizado por TOMALÁ GUARANDA ANDRÉS DARÍO, como requisito para obtener el título de Magister en Tecnologías de la Información.

TUTOR

Ing. Alicia Andrade Vera, Mgtr.

25 días del mes de marzo del año 2024



**UNIVERSIDAD ESTATAL PENÍNSULA
DE SANTA ELENA
FACULTAD DE SISTEMAS Y TELECOMUNICACIONES
INSTITUTO DE POSTGRADO**

DECLARACIÓN DE RESPONSABILIDAD

Yo, TOMALÁ GUARANDA ANDRÉS DARÍO

DECLARO QUE:

El trabajo de Titulación, Modelo basado en visión por computador para la predicción de osteoartritis en imágenes de rayos X. previo a la obtención del título en Magister en Tecnologías de la Información, ha sido desarrollado respetando derechos intelectuales de terceros conforme las citas que constan en el documento, cuyas fuentes se incorporan en las referencias o bibliografías. Consecuentemente este trabajo es de mi total autoría.

En virtud de esta declaración, me responsabilizo del contenido, veracidad y alcance del Trabajo de Titulación referido.

Santa Elena, a los 25 días del mes de marzo del año 2024

EL AUTOR



Firmado electrónicamente por:
ANDRÉS DARÍO TOMALÁ
GUARANDA

Andrés Darío Tomalá Guaranda



**UNIVERSIDAD ESTATAL PENÍNSULA
DE SANTA ELENA
FACULTAD DE CIENCIAS DE LA INGENIERÍA
INSTITUTO DE POSTGRADO**

CERTIFICACIÓN DE ANTIPLAGIO

Certifico que después de revisar el documento final del trabajo de titulación denominado MODELO BASADO EN VISIÓN POR COMPUTADOR PARA LA PREDICCIÓN DE OSTEOARTRITIS EN IMÁGENES DE RAYOS X, presentado por el estudiante, Andrés Darío Tomalá Guaranda fue enviado al Sistema Antiplagio Compilatio, presentando un porcentaje de similitud correspondiente al 5%, por lo que se aprueba el trabajo para que continúe con el proceso de titulación.

formato_compilatio



Nombre del documento: formato_compilatio.docx
ID del documento: c7f23d0ea27fe8d776d3afabf934390f79213b54
Tamaño del documento original: 3,68 MB

Depositante: ALICIA GERMANIA ANDRADE VERA
Fecha de depósito: 24/3/2024
Tipo de carga: interface
fecha de fin de análisis: 24/3/2024

Número de palabras: 7259
Número de caracteres: 48.288

TUTOR

Andrés Darío Tomalá Guaranda



**UNIVERSIDAD ESTATAL PENÍNSULA
DE SANTA ELENA
FACULTAD DE SISTEMAS Y TELECOMUNICACIONES
INSTITUTO DE POSTGRADO**

AUTORIZACIÓN

Yo, TOMALÁ GUARANDA ANDRÉS DARÍO

Autorizo a la Universidad Estatal Península de Santa Elena, para que haga de este trabajo de titulación o parte de él, un documento disponible para su lectura consulta y procesos de investigación, según las normas de la Institución.

Cedo los derechos en línea patrimoniales de artículo profesional de alto nivel con fines de difusión pública, además apruebo la reproducción de este artículo académico dentro de las regulaciones de la Universidad, siempre y cuando esta reproducción no suponga una ganancia económica y se realice respetando mis derechos de autor

Santa Elena, a los 25 días del mes de marzo del año 2024

EL AUTOR



Firmado electrónicamente por:
**ANDRÉS DARÍO TOMALÁ
GUARANDA**

Andrés Darío Tomalá Guaranda

AGRADECIMIENTO

A Dios.

A mis padres Germán y Yolanda (+).

A mi familia.

A mis amigos, José, Jhonny, Marjorie.

A mis docentes.

A mi tutora y amiga, Alicia.

DEDICATORIA

A mi esposa Katherine Alejandro Roca,

Que me incentivo a tomar esta decisión,

A mis hijas, Kenia y Karol,

Todo esto es por ustedes.

A papá, para que se sienta orgulloso,

A mamá, por su amor eterno.

Andrés D. Tomalá Guaranda

ÍNDICE GENERAL

TITULO DEL TRABAJO DE TITULACIÓN.....	I
TRIBUNAL DE SUSTENTACIÓN.....	II
CERTIFICACIÓN.....	III
DECLARACIÓN DE RESPONSABILIDAD.....	IV
DECLARO QUE:	IV
CERTIFICACIÓN DE ANTIPLAGIO	V
AUTORIZACIÓN	VI
AGRADECIMIENTO	VII
DEDICATORIA	VIII
ÍNDICE DE FIGURAS	XI
RESUMEN	XIII
ABSTRACT.....	XIII
INTRODUCCIÓN	1
CAPÍTULO 1. MARCO TEÓRICO REFERENCIAL.....	5
1.1. Revisión de literatura	5
1.2. Desarrollo teórico y conceptual	6
1.2.1. Osteoartrosis	6
1.2.2. Diagnóstico	7
1.2.3. Inteligencia Artificial.....	8
1.2.4. Clasificación de imágenes	9
1.2.5. Redes Neuronales Convulcionales.....	9
CAPÍTULO 2. METODOLOGÍA	10
2.1. Contexto de la investigación	10

2.2.	Diseño y alcance de la investigación	11
2.3.	Tipo y métodos de investigación.....	11
2.4.	Población y muestra	11
2.5.	Metodología de desarrollo.....	12
2.5.1.	Recopilación de datos	12
2.5.2.	Procesamiento de imágenes	15
2.5.3.	División del conjunto de datos.....	16
2.5.4.	Selección del modelo	17
2.5.5.	Entrenamiento del modelo	20
2.5.6.	Integración del modelo	21
CAPÍTULO 3. RESULTADOS Y DISCUSIÓN		24
CONCLUSIONES		35
RECOMENDACIONES.....		37
REFERENCIAS.....		38
ANEXOS		42

ÍNDICE DE FIGURAS

Figura 1. Parámetros de diagnóstico.....	8
Figura 2. Mapa especial de Santa Elena	10
Figura 3. Estructura del conjunto de datos	13
Figura 4. Imagen con etiqueta Normal	14
Figura 5. Imagen con etiqueta Osteoartrosis	14
Figura 6. Imgen con dimensiones distintas.....	15
Figura 7. Imagen sin normalización	16
Figura 8. Comparación de procesos.....	18
Figura 9. Distribución de modelos según Accuracy	19
Figura 10. Distribución de modelos por Millones de parámetros.....	20
Figura 11. Arquitectura de Django	22
Figura 12. Función de predicción	23
Figura 13. Matriz de confusión del modelo inicial.....	24
Figura 14. Curva PR	25
Figura 15. Curva de Accuracy	26
Figura 16. Curva de función de pérdida	27
Figura 17, Curva de Accuracy con modelo optimizado	28
Figura 18. Comparativa de métricas	28
Figura 19. Matriz de confusión de modelo optimizado	30
Figura 20. Resultado de la predicción	31
Figura 21. Evaluación de especialistas	32
Figura 22. Evaluación de aciertos.....	32

Figura 23. Arquitectura de MobilienetV2.....	42
Figura 24. Ejemplo de matriz de confusión.....	43
Figura 25. Fórmulas de métricas de evaluación	43
Figura 26. Interfaz de Usuario	44

RESUMEN

La osteoartritis es una enfermedad degenerativa de las articulaciones que causa dolor y rigidez. En este estudio, se empleó visión por computadora para desarrollar un modelo de detección de osteoartritis en imágenes de rayos X. El modelo fue entrenado con 3836 imágenes de rayos X de rodillas de pacientes de edad media y tercera edad. Se utilizó un método de aprendizaje profundo y se evaluó la precisión y eficiencia. Los resultados mostraron una alta precisión del 94% y una eficiencia del 86% luego del ajuste de hiperparámetros en la compilación del modelo, superando el promedio de predicción de los especialistas médicos. Esto sugiere que el modelo puede ser una herramienta efectiva para el diagnóstico asistido por computadora en osteoartritis, lo que podría mejorar el tratamiento y la atención médica de los pacientes afectados.

Palabras claves: Inteligencia Artificial, Visión por computador, Osteoartritis

ABSTRACT

Osteoarthritis is a degenerative joint disease that causes pain and stiffness. In this study, computer vision was used to develop a model for detecting osteoarthritis in X-ray images. The model was trained with 3836 X-ray images of knees from middle-aged and elderly patients. A deep learning method was used and the accuracy and efficiency were evaluated. The results showed a high accuracy of 94% and an efficiency of 86% after hyperparameter tuning in model compilation, surpassing the average prediction of medical specialists. This suggests that the model may be an effective tool for computer-aided diagnosis in osteoarthritis, which could improve the treatment and medical care of affected patients.

Keywords: Artificial Intelligence, Computer Vision, Osteoarthritis.

INTRODUCCIÓN

La osteoartritis es una enfermedad crónica degenerativa que afecta las articulaciones, causando dolor y rigidez que pueden limitar la movilidad y reducir la calidad de vida. Aunque puede afectar a personas de todas las edades, es más común en adultos mayores, especialmente en aquellos que tienen sobrepeso u obesidad. El 10 % de los hombres y el 18 % de las mujeres mayores de 60 años tienen osteoartritis sintomática (Vidal Fuentes, 2021). Desafortunadamente, muchas personas con osteoartritis no son diagnosticadas hasta que la enfermedad ha progresado a una etapa avanzada, lo que puede hacer que el tratamiento sea más difícil y menos efectivo. Para abordar este problema, es crucial identificar a las personas que están en riesgo de desarrollar osteoartritis lo antes posible. Una vez identificados, se pueden aplicar intervenciones preventivas y terapéuticas adecuadas para frenar o incluso detener la progresión de la enfermedad.

En los Estados Unidos de América se calcula que la población afectada podría pasar de 40 millones en 1995 a 59 millones para el año 2020 (Solis Cartas et al., 2015). La osteoartritis, en sus etapas iniciales, suele ser una afección sigilosa que avanza gradualmente sin mostrar síntomas notables. Esta característica insidiosa contribuye a una preocupante tendencia de subdiagnóstico, ya que las personas afectadas pueden no buscar atención médica hasta que los signos evidentes de dolor y deterioro articular se vuelven ineludibles. La gran afectación que producen estas afecciones en el cartílago articular, principal estructura anatómica afectada en la Osteoartrosis (OA), donde el proceso inflamatorio, los cambios metabólicos y el estrés oxidativo son los principales responsables de la destrucción de este (Solis Cartas et al., 2014).

En Ecuador la artrosis se considera una de las enfermedades crónicas que afecta a mayores de 60 años, por lo que su prevalencia es del 32.4% a nivel nacional (Ayala, 2017). Se considera que el sexo femenino es que tiene mayor posibilidad de desarrollar este tipo de patologías. Según (Quezada Balón & Camatón Tomalá, 2019), el 90% de los mayores a 60 años presentan síntomas de osteoartritis, pero no hay cifras finales porque muchas veces no se registran diagnósticos de este por falta de información o recursos tecnológicos. A pesar de existir información relevante sobre el tema, en ocasiones, no se puede detectar este tipo de dolencias por falta de análisis o interpretación de los datos recolectados.

Un diagnóstico tardío de osteoartritis puede afectar negativamente la calidad de vida del paciente, pues la enfermedad interfiere con las actividades diarias y el concepto de independencia (Quezada Balón & Camatón Tomalá, 2019). Además, aumenta los costes de cuidados y reduce la eficacia de los tratamientos existentes. Los tratamientos para la osteoartrosis suelen ser más efectivos en etapas tempranas de detección, porque en este punto el daño articular es mínimo y regenerativo. Por lo tanto, es fundamental aprovechar la oportunidad de un diagnóstico a tiempo lo que trascendería en mejores resultados para los pacientes.

En la rama médica y científica, existe una base de conocimiento sólida respecto a la osteoartrosis, que puede analizarse por grupos de edad, patrones de diagnóstico, entre otros. La tecnología puede ser una aliada que permita realizar diagnósticos más precisos y en menos tiempo, siendo de gran ayuda a la decisión médica y del tratamiento adecuado (López-González et al., 2021). Además, siendo la osteoartrosis una afección de interés general será posible concientizar a la población de la necesidad de un diagnóstico de esta enfermedad degenerativa.

Este estudio beneficiará a múltiples grupos al disminuir los tiempos de revisión y diagnósticos a partir de imágenes de rayos X y crear conciencia sobre la importancia del diagnóstico temprano de la osteoartritis. Dentro de estos grupos destacan, las personas de media y tercera edad, profesionales de la salud, investigadores, responsables del sistema de atención médica. El beneficio principal radica en tratamiento efectivo a partir del diagnóstico temprano de la enfermedad, lo que conlleva a menos intervenciones invasivas y menos gastos médicos.

En el campo metodológico se beneficia de la evaluación de herramientas de diagnóstico, que ayudan a identificar falencias en el sistema de detección actual. Otro beneficio es la recopilación de datos clínicos, que ayudarán a comprender parámetros de diagnóstico como sintomatología, tratamientos previos, entre otros. Asimismo, es importante colaborar con expertos en el área médica, enriqueciendo la comprensión de la problemática desde varias perspectivas. Adicionalmente, la gran cantidad de datos favorecerá el uso de herramientas tecnológicas para crear modelos de evaluación, identificar patrones y tendencias en el diagnóstico y tratamiento de la osteoartrosis.

Finalmente, este estudio generará beneficios interpersonales como la contribución al bienestar de los pacientes, empatía y sentido de propósito, beneficios sociales que influyen en la población en general a fin de concientizar sobre la osteoartritis, beneficios profesionales, como el reconocimiento del campo, el desarrollo de habilidades y la ampliación de conocimientos, y beneficios disciplinarios específicamente en la aplicabilidad directa de los resultados de esta investigación que proporcionarían un mejor enfoque sobre esta enfermedad a la comunidad científica y médica.

Formulación del problema de investigación

General

¿Cuáles son los principales factores que contribuyen al diagnóstico tardío de la osteoartritis en personas de edad media y tercera edad en los establecimientos de salud de la provincia de Santa Elena?

Específicas

¿Cuáles son las barreras sistémicas y de atención médica que pueden contribuir al retraso en el diagnóstico de la osteoartritis?

¿Qué herramientas tecnológicas podrían ayudar a diagnosticar con mayor precisión la osteoartritis?

¿Cómo pueden las intervenciones a nivel clínico y de políticas de salud promover la detección temprana de la osteoartritis y mejorar los resultados de los pacientes de edad media y tercera edad?

Objetivo General:

Desarrollar un sistema de diagnóstico asistido por visión por computadora mediante algoritmos avanzados de procesamiento de imágenes para detectar osteoartritis en imágenes de rayos X de pacientes de edad media y tercera edad.

Objetivos Específicos:

1. Elegir un modelo de inteligencia artificial adecuado para el análisis de imágenes a partir de la evaluación de factores de precisión, rendimiento y escalabilidad.
2. Implementar un modelo de Inteligencia Artificial mediante el entrenamiento de un conjunto de datos clínicos sobre diagnósticos de osteoartrosis.
3. Diseñar la arquitectura de una aplicación web para la comunicación del frontend con el modelo de Inteligencia Artificial.
4. Evaluar el comportamiento del modelo usando técnicas de medición estadística de las métricas de validación para determinar precisión y fiabilidad en la detección de osteoartritis en imágenes de rayos X de pacientes de edad media y tercera edad.

Planteamiento hipotético

Se plantea que al desarrollar un modelo basado en visión por computadora y aplicar algoritmos avanzados de procesamiento de imágenes en la detección de osteoartritis en radiografías de pacientes de edad media y tercera edad, se logrará mejorar significativamente la precisión y eficiencia del diagnóstico asistido por computadora en comparación con los métodos convencionales.

CAPÍTULO 1. MARCO TEÓRICO REFERENCIAL

1.1. Revisión de literatura

(González, 2015) en su artículo científico titulado “Modelos de aprendizaje computacional en reumatología nos indica que:

En medicina los modelos de aprendizaje computacional se han aplicado con éxito tanto a problemas motivados por la práctica clínica, como el diagnóstico asistido por ordenador, como a problemas de análisis de datos de investigación médica básica. En los últimos años ha habido un gran auge en la investigación y desarrollo de modelos de aprendizaje computacional aplicados al diagnóstico médico de diversas enfermedades y condiciones médicas.

(López-González et al., 2021) fue muy explícito en el siguiente apartado:

La aplicación de técnicas de inteligencia artificial (IA) en diversos campos de la medicina ha crecido de manera significativa en los últimos años. Este crecimiento se ha debido principalmente al progreso de la computación de altas prestaciones y al desarrollo de las técnicas de aprendizaje profundo (DL, por sus siglas en inglés), un subconjunto de algoritmos de IA que utilizan redes neuronales para aprender a resolver tareas específicas a partir de bases de datos etiquetadas por expertos.

(Morales Muñoz et al., 2015) en su artículo publicado en el Revista Colombiana de reumatología indica que:

Mediante el uso de redes neuronales artificiales se logró clasificar a pacientes sanos y pacientes con Artrosis Reumatoide, obteniendo un índice de confianza de 89.28% en las pruebas con matriz de confusión.

(Sajda, 2006) en “Aprendizaje de máquina para la detección y diagnóstico de enfermedades” nos dice que:

El aprendizaje automático ofrece un enfoque basado en principios para desarrollar algoritmos sofisticados, automáticos y objetivos para el análisis de datos biomédicos multimodales y de alta dimensión.

(Pouly et al., 2020) en “Inteligencia Artificial en el análisis de imágenes: fundamentos y nuevos desarrollos” nos explica que:

Desde 2017, ha habido varios informes de que la inteligencia artificial (IA) ha logrado un rendimiento comparable al de los expertos humanos en tareas de análisis de imágenes médicas. En 2018, con la primera ratificación de un algoritmo de visión por computadora como dispositivo médico, se allanó el camino para que estos métodos se convirtieran en parte integral de la práctica clínica moderna.

Se evidencia un avance sustancial en la aplicación de aprendizaje profundo e inteligencia artificial para el diagnóstico de enfermedades. La eficacia demostrada de algoritmos de aprendizaje profundo y redes neuronales en la clasificación de pacientes, junto con el reconocimiento de la inteligencia artificial como herramienta médica, señala un cambio paradigmático en la práctica clínica. Estos desarrollos prometen no solo una detección más temprana y precisa de enfermedades, sino también la integración progresiva de tecnologías de visión por computadora en la atención médica, marcando una era de colaboración para fines específicos.

1.2. Desarrollo teórico y conceptual

1.2.1. Osteoartrosis

La osteoartrosis es una enfermedad degenerativa que afecta principalmente a las articulaciones del cuerpo, provocando daño irreversible y alterando el estilo de vida de las personas afectadas. Esta afectación se presenta a partir de los 60 años, y su diagnóstico depende de síntomas y ante la ausencia de estos es probable que se presente un daño severo en el paciente. Actualmente la Inteligencia Artificial ha abordado en el campo de la medicina ayudando a procesar enormes cantidades de información para mejorar los procesos de diagnósticos de enfermedades. Por lo tanto, es necesario ahondar en los conceptos y teorías para encontrar una sinergia entre el uso de la inteligencia artificial y el diagnóstico de la osteoartrosis.

(Solis Cartas et al., 2014) en su artículo de investigación dice lo siguiente:

“La osteoartritis es una afección que ocasiona morbilidad desde tiempos remotos. Se ha informado que afecta al 10 % de los adultos mayores de 60 años y daña cualquier articulación, aunque las más afectadas, son la rodilla y la cadera”

Otro aspecto importante de esta enfermedad es la relación que tiene con el sexo femenino, (Solis Cartas et al., 2014) explicó que:

En relación con el sexo podemos decir que es más prevalente en mujeres que en hombres. Las mujeres presentan mayor frecuencia de obesidad, menor tono muscular y más laxitud articular, factores estos que condicionan inestabilidad articular y favorecen los micro traumas repetitivos y por tanto el daño de la articulación, además que factores hormonales también pueden influir en este sentido señalándose que los estrógenos pudieran ejercer un efecto anabólico sobre los condrocitos frenando la aparición y desarrollo de la Osteoartrosis.

(Solis Cartas et al., 2015) en su artículo llamado Osteoartritis. Características sociodemográficas, concluye que:

“La edad promedio fue de 65.32 años. La mayor frecuencia de género correspondió al género femenino con un 77 %.”

1.2.2. Diagnóstico

En el artículo de investigación de (Solis Cartas et al., 2014) llamado “Osteoartritis. Características sociodemográficas”, detalla los parámetros de diagnóstico para esta enfermedad y que se muestran en la Figura 1:

Figura 1. Parámetros de diagnóstico

Localización	Criterios
Rodilla	<ol style="list-style-type: none"> 1. Presencia de dolor la mayor parte de los días durante el último mes, 2. Presencia de osteofitos 3. Líquido sinovial con características mecánicas 4. Edad mayor de 40 años 5. Rigidez matinal menor de 30 minutos en la articulación afectada 6. Crepitación rotuliana <p><i>Se considera diagnóstico la presencia de los 2 primeros o la presencia del primero más una de las siguientes combinaciones: 3-5-6 o 4-5-6.</i></p>
Cadera	<p>Presencia de dolor la mayor parte de los días durante el último mes más 2 de los siguientes 3 criterios:</p> <ul style="list-style-type: none"> • Pinzamiento radiológico de la articulación coxofemoral • Presencia de osteofitos femorales o acetabulares • VSG menos de 20 mm/h
Manos	<ul style="list-style-type: none"> • Presencia de dolor, congelación o rigidez de la mano la mayor parte de los días durante el último mes • Proliferación osteocartilaginosa en 2 o más de las 10 articulaciones seleccionadas • Tumefacción en menos de 2 articulaciones metacarpofalángicas. <p><i>Además:</i></p> <ul style="list-style-type: none"> • Proliferación osteocartilaginosa en 2 o más articulaciones interfalángicas distales • Deformidad en una o más de las 10 articulaciones seleccionadas <p><i>Articulaciones seleccionadas: 1ra MCF, 1ra y 2da IFP, 1ra y 2da IFD, todas de forma bilateral</i></p>
Columna vertebral	<p>No existe una definición precisa de artrosis vertebral.</p> <p>Se caracteriza por pérdida focal del cartilago articular y radiológicamente se manifiesta por: estrechamiento de espacio articular, esclerosis y la presencia de osteofitos en cuerpo vertebral o articulaciones interapofisarias (uncoartrosis), puentes intervertebrales.</p>

Fuente: (Solis Cartas et al., 2014)

1.2.3. Inteligencia Artificial

Uno de los modelos de Inteligencia Artificial más usados en la clasificación de objetos es la visión por computador, (Tomalá Guaranda, 2021) explica que:

Las técnicas de visión por computador permiten extraer información del mundo real a partir de una imagen. Una de las etapas críticas es la adquisición de la imagen, parámetros como: la iluminación, la densidad de píxeles de la cámara, son la clave del buen funcionamiento de un sistema de reconocimiento y clasificación.

“La finalidad de la visión por computador es la de modelar y automatizar procesos de reconocimiento visual, es decir, distinguir entre objetos” (Alejandro Roca, 2021).

1.2.4. Clasificación de imágenes

“El método de aprendizaje profundo más utilizado para diagnosticar enfermedades médicas es la tecnología de red neuronal convolucional (CNN), especialmente para datos basados en imágenes” (Nagamani & Sudhakar, 2023).

“La evaluación del desempeño de una clasificación multiclase se realiza de la misma manera que una clasificación binaria simple compuesta de dos clases, a saber: positiva y negativa” (Boutalline et al., 2022).

Los algoritmos basados en IA, o más precisamente en aprendizaje automático (ML), tienen capacidades que les permiten aprender los patrones contenidos en los datos a partir de los datos mismos. Entre los algoritmos de mejor rendimiento se encuentran las redes neuronales artificiales (ANN) o, más precisamente, las redes neuronales convolucionales (CNN). (Car et al., 2021)

1.2.5. Redes Neuronales Convolucionales


Las redes neuronales convolucionales (CNN o ConvNets) son un grupo popular de redes neuronales que pertenecen a una familia más amplia de métodos conocidos como aprendizaje profundo. El secreto de su éxito reside en su arquitectura cuidadosamente diseñada, capaz de considerar las características locales y globales de los datos de entrada. Inicialmente, las CNN se diseñaron para procesar datos de imágenes de manera eficiente y, para ello, se desarrollaron con propiedades como conectividad local, invariancia espacial y características jerárquicas. (Skansi & Skansi, 2018)

CAPÍTULO 2. METODOLOGÍA

2.1. Contexto de la investigación

Este trabajo de investigación se realizará en Santa Elena, Santa Elena, Ecuador, cuya ubicación espacial es: 2.227° latitud sur y 80.858° longitud oeste (IGM, 2017). La Figura 2 muestra una referencia espacial del lugar antes mencionado.

Figura 2. Mapa especial de Santa Elena



Fuente: (IGM, 2017)

Desafortunadamente no se tienen datos estadísticos referentes a la evaluación y diagnósticos de personas con osteoartritis. “El impacto de la osteoartritis tiene un elevado costo económico relacionado con las necesidades para el cuidado” (Quezada Balón & Camatón Tomalá, 2019).

Según datos de la Sociedad de Geriatria del Ecuador, la artrosis afecta al sesenta por ciento de personas mayores de 65 años, y las lesiones por caídas son más frecuentes en los adultos mayores (Quezada Balón & Camatón Tomalá, 2019).

2.2. Diseño y alcance de la investigación

Según el autor (Malavé Rosales, 2022), la investigación no experimental observa los fenómenos tal y como se muestran en su contexto natural para analizarlos. Este enfoque encaja en esta investigación debido a que va a predecir diagnósticos de personas con osteoartrosis y cuyos resultados ayuden a los especialistas a tomar decisiones frente al diagnóstico final.

(Malavé Rosales, 2022) dice que la correlación de los datos se evalúa midiendo una variable y asociándola con las demás, por lo tanto, en este trabajo de investigación se relacionará la imagen de rayos X con un diagnóstico preestablecido usando visión por computador y se evaluará con el diagnóstico de un especialista.

2.3. Tipo y métodos de investigación

Este trabajo de investigación usa la recolección de datos para probar hipótesis, realiza un análisis estadístico para establecer patrones y probar teorías, por lo tanto, tiene un enfoque cuantitativo (Malavé Rosales, 2022).

El método de investigación analítico es el usado para iniciar este proyecto debido al tamaño de la colección de datos usados para entrenar una red neuronal encargada de predecir los diagnósticos de osteoartrosis. Asimismo, se usa el método hipotético-deductivo porque se intenta realizar predicciones con un alto índice de confianza.

2.4. Población y muestra

La población objetivo se enfoca en aquellas personas que utilizarán el sistema desarrollado, compuesta por profesionales de la salud especializados en el tratamiento de enfermedades osteoarticulares. Esta población incluye a tres traumatólogos y dos terapeutas, cuya experiencia y formación los hacen idóneos para evaluar la eficacia y utilidad del sistema en el contexto clínico. Los traumatólogos son médicos especializados

en el diagnóstico y tratamiento de lesiones musculoesqueléticas, mientras que los terapeutas están capacitados en la rehabilitación física y el manejo de enfermedades crónicas como la osteoartritis. La selección de estos profesionales se hizo intencionalmente, considerando su experiencia y especialización en traumatología y terapia, y se espera que su participación deba una valiosa retroalimentación sobre el sistema desarrollado, enriqueciendo su validez y aplicabilidad en el entorno médico real.

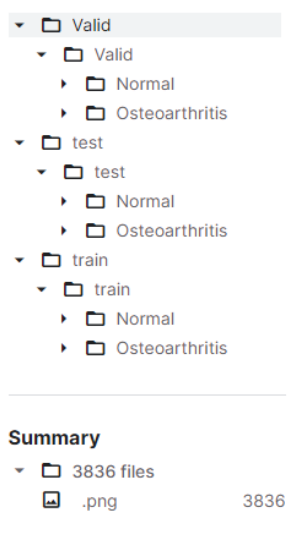
2.5. Metodología de desarrollo

2.5.1. Recopilación de datos

La recopilación de datos para este proyecto se llevó a cabo en la plataforma Kaggle (Kaggle, 2024), una comunidad en línea que proporciona acceso a una amplia variedad de conjuntos de datos en diferentes áreas, incluida la medicina. Se seleccionó un conjunto de datos específico que incluía imágenes médicas etiquetadas con la presencia o ausencia de osteoartritis. Este conjunto de datos fue elegido por su relevancia para el objetivo del proyecto y su disponibilidad para su descarga gratuita.

En total, se recopilaron 3836 imágenes de osteoartritis de este conjunto de datos de Kaggle. Estas imágenes abarcan una variedad de casos clínicos, incluyendo diferentes grados de gravedad de la enfermedad y variaciones en la ubicación de las articulaciones afectadas. Algunas imágenes pueden mostrar articulaciones en diferentes ángulos o condiciones de iluminación, lo que proporciona una diversidad de datos para entrenar y evaluar los modelos de predicción.

Figura 3. Estructura del conjunto de datos



Fuente: Elaboración propia

Cada imagen en el conjunto de datos está asociada con una etiqueta que indica si la osteoartritis está presente o no, como se muestra en Figura 3. Estas etiquetas son fundamentales para el aprendizaje supervisado, ya que permiten que los modelos de predicción aprendan a reconocer patrones en las imágenes que están relacionados con la presencia de la enfermedad. La precisión y la consistencia de estas etiquetas son aspectos críticos que se deben tener en cuenta durante el proceso de entrenamiento y evaluación del modelo.


En la figura 4 se muestra una imagen con etiqueta “Normal”, mientras que en la figura 5 se presenta una imagen con la etiqueta “Osteoartritis”.

Figura 4. Imagen con etiqueta Normal



Fuente: Elaboración propia

Figura 5. Imagen con etiqueta Osteoartrosis




Fuente: Elaboración propia

2.5.2. Procesamiento de imágenes

El procesamiento de imágenes es una etapa crucial en el preprocesamiento de datos para tareas de visión por computadora. En este proyecto, se aplicaron diversas técnicas de procesamiento de imágenes para preparar los datos antes de entrenar los modelos de predicción de osteoartritis.

Figura 6. Imgen con dimensiones distintas



Fuente: Elaboración propia

Una de las técnicas utilizadas fue el redimensionamiento de las imágenes para asegurar que todas tuvieran el mismo tamaño. Esto es importante para garantizar la compatibilidad de las imágenes durante el entrenamiento del modelo. Como se puede observar en la Figura 6, las dimensiones no corresponden a la medida de relación 1:1 como se muestra en la Figura 5. Además, se aplicó normalización a los valores de píxeles para estandarizar el rango de intensidades de las imágenes, lo que ayuda al modelo a converger más rápido durante el entrenamiento. El conjunto de datos no sólo tiene imágenes de rodillas individuales, si no también radiografías ambas rodillas en conjunto, tal como se muestra en la Figura 7.

Figura 7. Imagen sin normalización



Fuente: Elaboración propia

Otra técnica comúnmente empleada fue el aumento de datos, que implica la generación de nuevas imágenes modificando ligeramente las existentes. Esto se realizó mediante operaciones como rotaciones, inversiones, desplazamientos y cambios de brillo y contraste. El aumento de datos aumenta la diversidad del conjunto de datos de entrenamiento, lo que puede ayudar a prevenir el sobreajuste y mejorar el rendimiento del modelo en datos no vistos.

2.5.3. División del conjunto de datos

La división del conjunto de datos es una práctica estándar en el aprendizaje automático para evaluar el rendimiento de los modelos en datos no vistos durante el entrenamiento. En este proyecto, se dividió el conjunto de datos en tres subconjuntos principales: entrenamiento, validación y prueba.

El conjunto de datos se dividió en un conjunto de entrenamiento, que se utiliza para entrenar el modelo, un conjunto de validación, que se utiliza para ajustar los hiperparámetros del modelo y tomar decisiones de entrenamiento, y un conjunto de prueba, que se utiliza para evaluar el rendimiento final del modelo.

La proporción de la división del conjunto de datos puede variar dependiendo del tamaño total del conjunto de datos y la complejidad del problema. Por ejemplo, una división común puede ser del 70% para entrenamiento, 15% para validación y 15% para prueba, tal como sugiere (Vrigazova, 2021).

Es importante realizar esta división de manera aleatoria para evitar sesgos en los conjuntos de datos resultantes. Además, hay que cuidar que las distribuciones de clases

en los conjuntos de datos de entrenamiento, validación y prueba representen la distribución general del conjunto de datos original.

La división adecuada del conjunto de datos garantiza una evaluación justa y precisa del rendimiento del modelo y ayuda a identificar posibles problemas como el sobreajuste durante el entrenamiento. Esta práctica es fundamental para el desarrollo efectivo de modelos de predicción de osteoartritis utilizando visión por computadora.

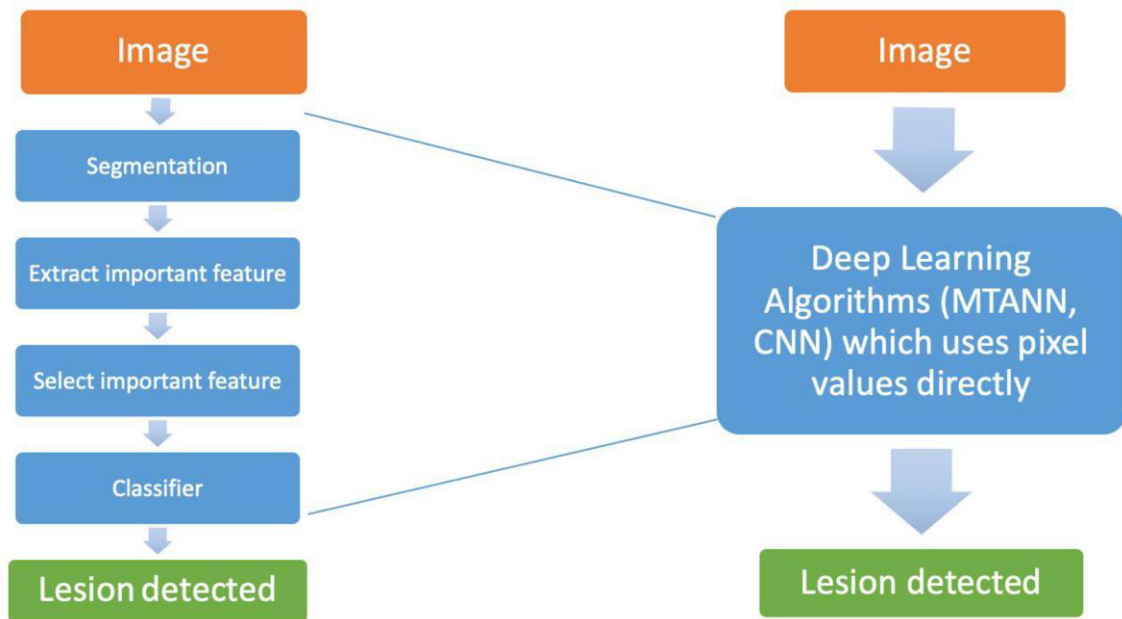
2.5.4. Selección del modelo

El aprendizaje profundo, dentro del campo más amplio del aprendizaje automático y la inteligencia artificial, se destaca por su capacidad para generar conclusiones automáticamente, sin requerir supervisión humana (Yick et al., 2022). Esto se logra a través de algoritmos y modelos que pueden extraer y analizar datos, incluidas imágenes médicas, sin la necesidad de un etiquetado manual. Esto representa un avance significativo en comparación con el aprendizaje automático tradicional, ya que permite automatizar y agilizar el proceso de análisis de datos.

En el aprendizaje profundo, especialmente cuando se trabaja con imágenes, los algoritmos utilizan los valores de píxeles directamente como entrada (Yick et al., 2022). Esto contrasta con el enfoque del aprendizaje automático "tradicional", donde se extraen características específicas de la imagen, como el contraste, el tamaño o la forma, y se utilizan como datos de entrada. En el aprendizaje profundo, el modelo aprende automáticamente a identificar patrones y características relevantes de los píxeles de la imagen, lo que puede simplificar el proceso de preprocesamiento de datos y potencialmente mejorar la precisión del modelo (Tiulpin et al., 2019).

Dos clases de modelos de aprendizaje profundo son populares en imágenes médicas: las redes neuronales convolucionales (CNN) y las redes neuronales artificiales de entrenamiento masivo (MTANN) (Yick et al., 2022). En la figura 8 se muestra una comparación del proceso.

Figura 8. Comparación de procesos




Fuente: Elaboración propia

MobileNet es una Red Neuronal Convolutiva reducida, diseñada específicamente para aplicaciones y dispositivos móviles. La idea básica detrás de su éxito es la sustitución de la clásica convolución por dos nuevos procesos distintos, una convolución profunda y puntualmente separable (Boutalline et al., 2022). En la convolución profunda cada canal es procesado por separado, por otro lado, la convolución puntual consiste en combinar las convoluciones profundas, en la llamada convolución 1 x 1 (Boutalline et al., 2022).

En el contexto de un sistema de diagnóstico asistido por visión por computadora para detectar osteoartritis en imágenes de rayos X, se comparan modelos de inteligencia artificial. El diseño de redes neuronales profundas (DNN) con una complejidad creciente capaz de mejorar el rendimiento de la competencia. ImageNet-1k juega un papel central en el avance de la tecnología más avanzada también en otras tareas de visión.

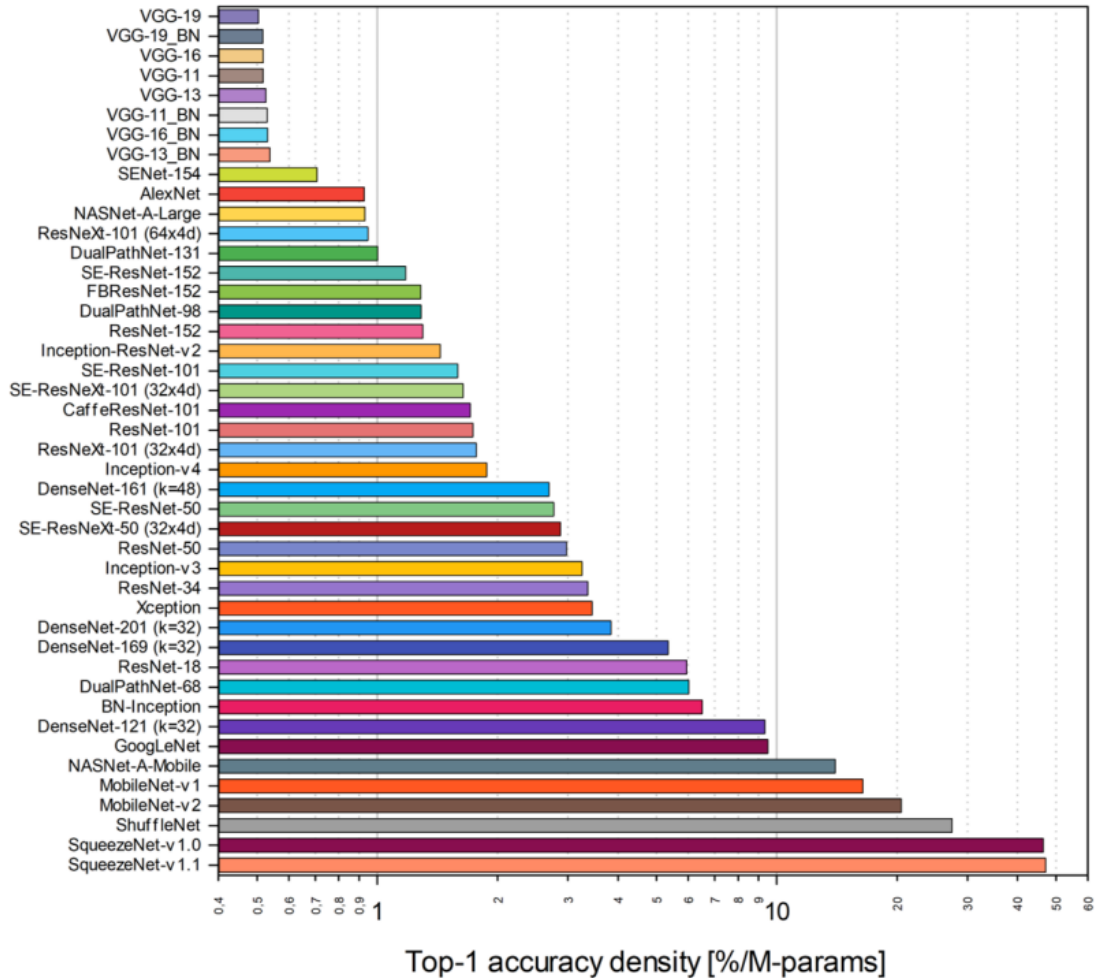
Figura 9. Distribución de modelos según Accuracy



Fuente: (Boutalline et al., 2022)

MobileNetV2, conocido por su eficiencia computacional y velocidad, tal como se puede observar en la Figura 9, destaca por su arquitectura liviana, siendo adecuado para aplicaciones en tiempo real. ResNet50, por otro lado, ofrece una mayor profundidad y capacidad de representación gracias a su arquitectura residual, aunque con mayores requerimientos de recursos.

Figura 10. Distribución de modelos por Millones de parámetros



Fuente: (Boutalline et al., 2022)

En la Figura 10 se puede observar la comparación en la efectividad de las arquitecturas en relación con los millones de parámetros que se usan para el entrenamiento. Se puede notar que MobilenetV2 se encuentra entre los modelos más efectivos.

2.5.5. Entrenamiento del modelo

Se entrena un modelo a partir de una red neuronal convolucional con la arquitectura de MobileNet V2, utilizando los pesos de “imagenet”, y analizando el conjunto de imágenes de entrenamiento. La configuración de hiper parámetros queda establecida de la siguiente manera:

- Épocas: 50
- Número de neuronas: 1024

- Activación: relu
- Forma de entrada: 224
- Tamaño de lote: 32
- Rango de aprendizaje: 0,0001

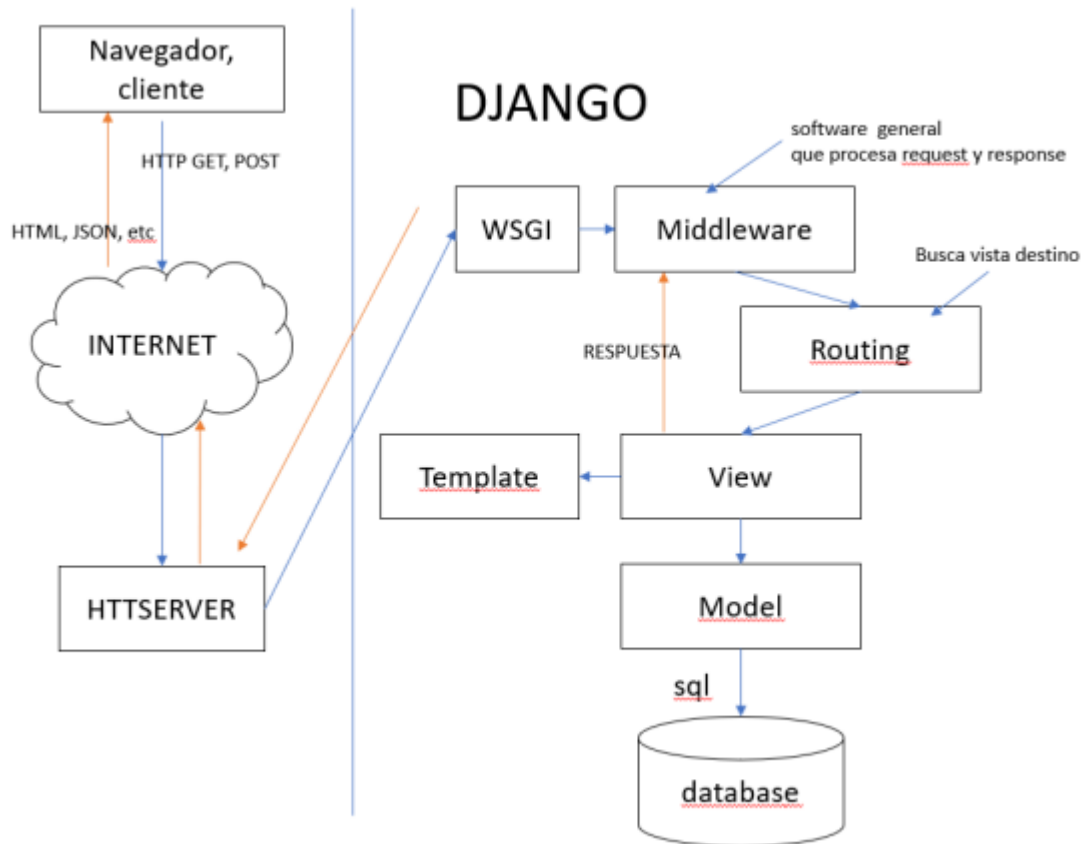
La construcción y entrenamiento del modelo se realizó en Google Colab (*Google Colaboratory*, 2024), debido a su gran facilidad para desarrollar código Python y por su ambiente aislado con capacidad computacional integrando núcleos de CUDA (NVidia, 2023). La arquitectura base del modelo se basa en MobilenetV2 que se encuentra alojado en la librería Keras perteneciente al framework Tensorflow (*TensorFlow*, 2024) que es uno de los paquetes de librerías más robustos destinados a la integración, análisis, construcción y despliegue de modelos de inteligencia artificial.

Las capas de entradas pertenecen a MobilenetV2, que se enlazan a las capas intermedias con 1024 neuronas con activación relu y finalmente se encuentran dos neuronas de predicción con activación softmax. La compilación se realiza con el optimizador Adam y los hiper parámetros establecidos previamente. Los datos de entrenamiento y validación son ingresados a la función activadora y el resultado se guarda en un archivo con formato h5 que contiene los pesos capturados en cada época, asimismo los metadatos obtenidos muestran el proceso de aprendizaje de la red neuronal.

2.5.6. Integración del modelo

La integración del modelo entrenado se realiza mediante el desarrollo y despliegue de un microservicio de backend usando el lenguaje de programación Python (*Welcome to Python.Org*, 2024) y el framework web Django (*Django*, 2024). Django es un software que puede utilizar para desarrollar aplicaciones web de forma rápida y eficiente (*¿Qué es Django?*, 2024). El archivo del modelo es cargado dentro del repositorio del backend y ejecutado cuando se realizan las predicciones, evitando un consumo innecesario de recursos y optimización en tiempos de respuesta.

Figura 11. Arquitectura de Django



Fuente: Elaboración propia

La figura 11 muestra la arquitectura de Django que se basa en el paradigma Modelo, Vista, Template que constituyen un sistema cerrado que engloba tanto frontend y backend facilitando la comunicación entre cliente y servidor. El esquema Modelo que posee Django se basa en los procesos o controladores que tiene la aplicación y aquí donde se realiza la integración del “modelo” de inteligencia artificial obtenido a partir del entrenamiento.

Además, la Figura 12 muestra la función de predicción en la arquitectura, destacando cómo se utiliza el modelo de inteligencia artificial dentro del sistema.

Figura 12. Función de predicción

```
def prediccion(request):
    print(request.FILES)
    if request.method == 'POST' and request.FILES['imagen']:
        imagen_cargada = request.FILES['imagen']
        image = Image.open(imagen_cargada)
        image = np.array(image)
        image = cv2.cvtColor(image, cv2.COLOR_BGR2RGB) # Convierte BGR a RGB
        image = cv2.resize(image, (224, 224)) # Ajusta al tamaño de entrada de MobileNetV2
        image = image / 255.0 # Normaliza los valores de píxeles
        image = np.expand_dims(image, axis=0) # Agrega una dimensión para el lote
        predictions = model.predict(image)
        print(predictions)
        classes = ["Normal", "Osteoarthritis"]
        # Las predicciones es un arreglo de probabilidades para cada clase
        # Si tienes dos clases, puedes obtener la clase con mayor probabilidad de esta manera:
        predicted_class = np.argmax(predictions)
        print("Predicción: El paciente es diagnosticado con '" + classes[predicted_class] + "'")
```

Fuente: Elaboración propia

CAPÍTULO 3. RESULTADOS Y DISCUSIÓN

Las métricas de precisión, recall y F1-score proporcionan una comprensión detallada del rendimiento del modelo en la tarea de predicción de osteoartritis.

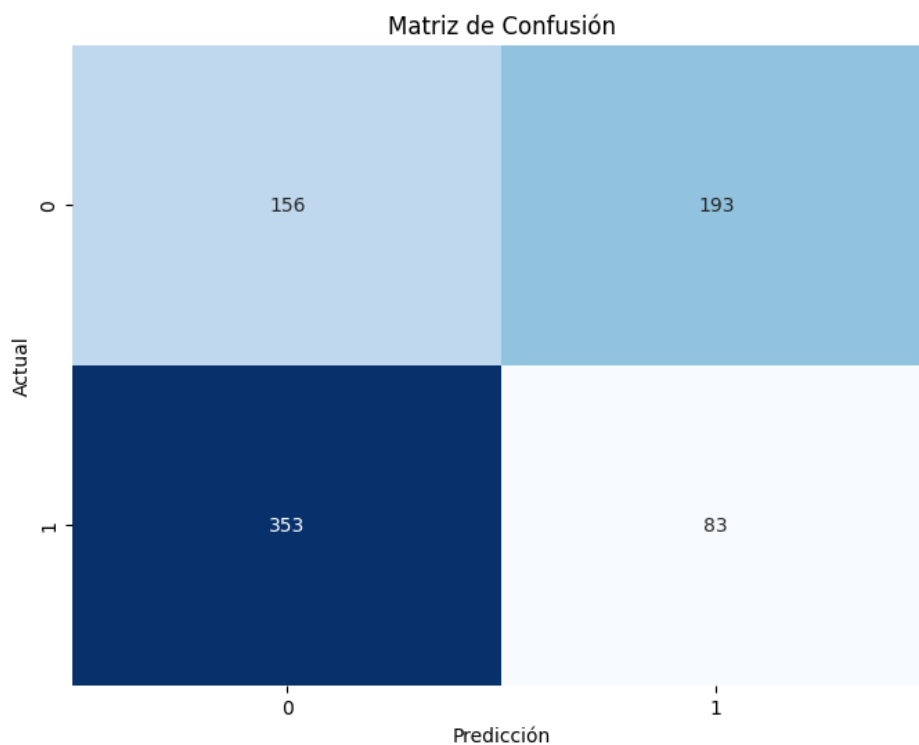
Precisión: La precisión del modelo es del 30.65%. Esto significa que aproximadamente el 30.65% de las instancias clasificadas como positivas fueron realmente positivas.

Recall: El recall, también conocido como sensibilidad, es del 44.70%. Esto indica que el modelo logra identificar correctamente el 44.70% de todas las instancias positivas en el conjunto de datos.

F1-score: El F1-score es una medida de precisión y recall balanceadas, y en este caso es del 36.36%. Esta métrica tiene en cuenta tanto la precisión como el recall, proporcionando una evaluación general del rendimiento del modelo.

Matriz de Confusión: La matriz de confusión proporciona una representación visual de las predicciones del modelo en comparación con las etiquetas verdaderas. La Figura 13 muestra la matriz de confusión del modelo inicial.

Figura 13. Matriz de confusión del modelo inicial.




Fuente: Elaboración propia

En la matriz de confusión, los verdaderos negativos (TN) son 156, los falsos positivos (FP) son 193, los verdaderos positivos (TP) son 83 y los falsos negativos (FN) son 353. Esta matriz revela la distribución de las predicciones del modelo y proporciona información sobre los tipos de errores que comete.

La Figura 14 muestra la curva de precisión-recall (PR), una herramienta crucial para evaluar el rendimiento de un modelo de clasificación, particularmente en escenarios de desequilibrio de clases.

Figura 14. Curva PR




Fuente: Elaboración propia

La curva de precisión-recall (PR) es una herramienta crucial para evaluar el rendimiento de un modelo de clasificación, particularmente en escenarios de desequilibrio de clases. En este gráfico, el eje X representa el recall, que indica la capacidad del modelo para identificar correctamente las instancias positivas en el conjunto de datos. Por otro lado, el eje Y representa la precisión, que cuantifica la proporción de predicciones positivas

correctas. La curva PR muestra cómo varía la precisión en función del recall para diferentes umbrales de decisión del modelo, buscando idealmente acercarse al rincón superior derecho, lo que indicaría una alta precisión y recall simultáneamente.

Una métrica importante asociada con la curva PR es el área bajo la curva (AUC-PR), que proporciona una medida cuantitativa del rendimiento del modelo, que para este caso obtuvo 0,32 (Ver figura 15). Un valor de AUC-PR cercano a 1 indica un modelo altamente preciso y sensible en la clasificación positiva, mientras que valores más bajos sugieren un rendimiento menos óptimo.


Figura 15. Curva de Accuracy



Fuente: Elaboración propia

La Figura 16 representa la curva de función de pérdida, que, junto con la precisión, proporciona información crucial sobre el progreso y la capacidad del modelo durante el entrenamiento.

Figura 16. Curva de función de pérdida




Fuente: Elaboración propia

El análisis de las curvas de aprendizaje revela el progreso del modelo a lo largo del entrenamiento. Inicialmente, el modelo mostraba una pérdida de 0.4808 y una precisión de 0.7476 en el conjunto de entrenamiento. Estos valores indican que el modelo necesitaba mejorar su capacidad para ajustarse a los datos y clasificar correctamente las muestras. Sin embargo, después de 10 épocas, se observa una mejora notable, con una pérdida reducida a 0.2960 y una precisión aumentada a 0.8684. Estos resultados señalan un avance significativo en la capacidad del modelo para aprender de los datos de entrenamiento y mejorar su capacidad de clasificación, indicando una mejora progresiva en su desempeño durante el entrenamiento.

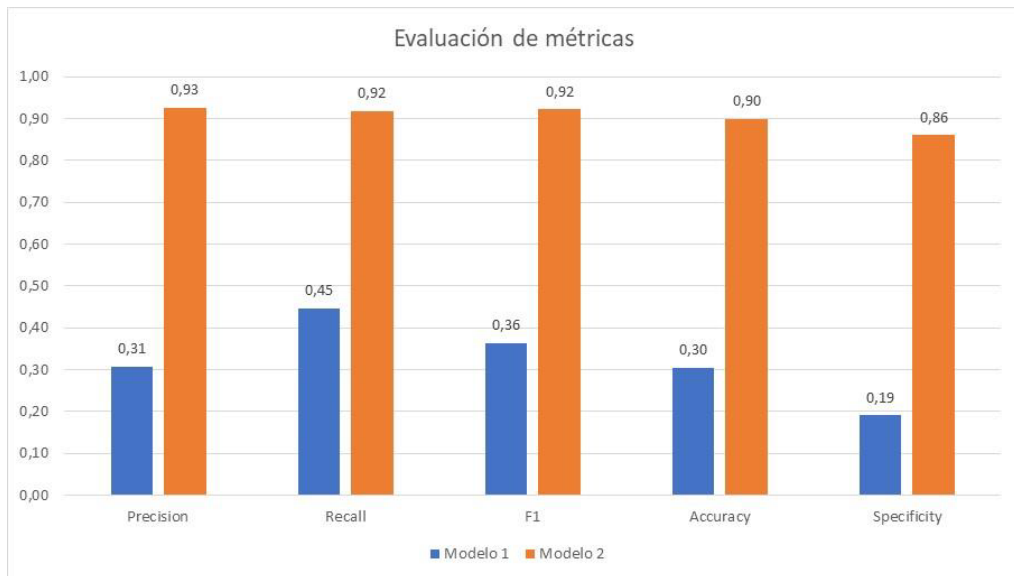
Es evidente que el modelo mostró un rendimiento bajo debido a su incapacidad de realizar predicciones correctas, tal y como se puede observar en la matriz de confusión. Tras ajustar los hiperparámetros y el entrenamiento con 100 épocas, se obtuvo una curva de Accuracy mejorada, como se muestra en la Figura 17.

Figura 17, Curva de Accuracy con modelo optimizado



Fuente: Elaboración propia

Figura 18. Comparativa de métricas



Fuente: Elaboración propia

El análisis comparativo entre los dos modelos entrenados presentado en la Figura 18 revela una mejora significativa en el rendimiento del segundo modelo en comparación con el primero en todas las métricas evaluadas, para fines de entendimiento el primer modelo entrenado a 10 épocas será Modelo 1 y el modelo ajustado será Modelo 2.

Comenzando con la precisión, el modelo 1 alcanza un valor de 0.3065, lo que indica que solo el 30.65% de las muestras clasificadas como positivas son realmente positivas. En contraste, el modelo 2 muestra una mejora sustancial en la precisión, alcanzando un valor de 92.53%. Esta mejora sugiere una capacidad mucho mayor del modelo 2 para identificar correctamente las muestras positivas, con aproximadamente el 92.53% de las predicciones correctas. Esta diferencia en la precisión entre los dos modelos sugiere una mejora significativa en la capacidad de clasificación del modelo 2 en comparación con el modelo 1.


En cuanto al recall, el modelo 1 muestra un valor de 0.4470, lo que significa que identifica correctamente el 44.70% de todas las muestras positivas en el conjunto de datos. Por otro lado, el modelo 2 tiene un recall de 0.9181, lo que indica una mejora sustancial en la capacidad del modelo para detectar muestras positivas después de un entrenamiento más prolongado. Esta mejora en el recall del modelo 2 sugiere una mayor sensibilidad para identificar casos positivos en comparación con el modelo 1.

Además de la precisión y el recall, el modelo 2 también muestra una mejora en el F1-score, que combina precisión y recall en una sola métrica. El F1-score del modelo 1 es de 0.3636, mientras que el del modelo 2 es de 0.9217. Esta diferencia refleja una mejora general en el rendimiento del modelo 2 en comparación con el modelo 1, ya que el F1-score más alto indica un mejor equilibrio entre precisión y recall.

El modelo inicial, entrenado durante 10 épocas, muestra un accuracy de 0.3045, lo que indica que solo el 30.45% de todas las predicciones son correctas. En contraste, el modelo mejorado, entrenado durante 100 épocas, presenta un significativo aumento en el accuracy, alcanzando un valor de 0.8981. Esta mejora sugiere que el modelo 2 puede hacer predicciones precisas que el modelo 1. Esto se refleja en una mayor proporción de predicciones correctas en el conjunto de datos de evaluación.

En cuanto a la métrica de specificity, el modelo 1 muestra un valor de 0.1904, mientras que el modelo 2 presenta una mejora considerable, con un specificity de 0.8603. Esto indica que el modelo 2 tiene una mejor capacidad para identificar correctamente las muestras negativas, reduciendo así el número de falsos positivos. Esta mejora en la especificidad sugiere una mayor capacidad del modelo 2 para discriminar entre las clases positiva y negativa, lo que contribuye a una mejora general en su capacidad de clasificación.

Figura 19. Matriz de confusión de modelo optimizado



Fuente: Elaboración propia

Esta matriz de confusión (Figura 19), correspondiente al modelo entrenado durante 100 épocas, muestra una mejora significativa en la capacidad de clasificación. Se clasificaron correctamente 471 muestras como negativas y 234 muestras como positivas, lo que indica una tasa de verdaderos positivos (TP) y verdaderos negativos (TN) considerablemente más alta en comparación con el primer modelo. Además, se observa una reducción notable en la cantidad de falsos positivos (42) y falsos negativos (38) en comparación con el primer modelo. Esto sugiere una mejora sustancial en la capacidad del modelo para evitar errores de clasificación, lo que resulta en una mejor precisión, recall y accuracy en

la clasificación de muestras de osteoartritis tal como se ha registrado en graficas anteriores.

El modelo por sí sólo no es capaz de predecir y para lo cual, se desarrolló una función activadora (Figura 12) como microservicio de backend dentro de la arquitectura de Django. Adicionalmente, se desplego un aplicativo web con una interfaz de usuario sencilla (Anexo 3), que les permita a los evaluadores interactuar con el modelo entrenado y sus predicciones. La imagen cargada en el frontend es almacenada temporalmente donde se reconstruye la imagen en base64 para su posterior análisis de la red neuronal convolucional.


En términos de estructura de red, MobileNetV2 toma una imagen de entrada y produce una distribución de probabilidad sobre las clases de salida. La entrada se procesa a través de múltiples bloques de construcción, seguidos de una capa de agrupación global promedio y una capa completamente conectada con función de activación softmax para la clasificación final. Las clases de salida retornan la probabilidad que tiene la imagen de entrada con respecto a las clases con las que fue entrenada la red. En la figura 20 se muestra una captura del log del servidor Django donde se puede visualizar el flujo de trabajo de la función de predicción, se carga la imagen de formato PNG, se analiza durante 606 milisegundos, luego compara las etiquetas de clase con los índices y muestra la predicción. Esta información es enviada al frontend para tener una representación visual de la predicción obtenida.

Figura 20. Resultado de la predicción

```
<MultiValueDict: {'imagen': [<InMemoryUploadedFile: 9099440R.png (image/png)>]}>
1/1 [=====] - 1s 606ms/step
Etiquetas de predicción: ['Normal', 'Osteoarthritis']
Indices de predicción del modelo: [[0.95760626 0.04239368]]
Predicción: El paciente es diagnosticado con 'Normal'
[24/Mar/2024 13:53:31] "POST /prediccion/ HTTP/1.1" 200 116
```


El enfoque de evaluación que se realizó mediante el análisis de la población objetivo revela una diferencia significativa en la precisión de los diagnósticos. Puesto que cada especialista pudo analizar visualmente cada imagen de rayos X y diagnosticar de acuerdo con su experticia en el área de traumatología. Dando como resultado los siguientes datos:

Figura 21. Evaluación de especialistas



Fuente. Elaboración propia

Figura 22. Evaluación de aciertos



Fuente. Elaboración propia

El diagnóstico de cada especialista y la predicción del modelo se realizó para veinte imágenes arbitrariamente seleccionadas, con equilibrio de clases, es decir diez etiquetadas como normal (cero) y diez más con etiqueta de osteoartritis (uno) (Anexo 4). El modelo obtuvo mayor cantidad de predicciones individuales correctas en referencia a la etiqueta, tal como se muestra en la Figura 21, tomando en cuenta que se realizaba una predicción cada vez que el especialista realizaba su diagnóstico. Este proceso ayudó a evaluar incluso

la capacidad del modelo para coincidir con su predicción anterior y se pudo determinar que tuvo un promedio de error del 3%.

Los resultados expuestos en Figura 22 muestran que el sistema logró una tasa de aciertos del 94% en la detección de osteoartritis en las imágenes de rayos X seleccionadas aleatoriamente. Por otro lado, el promedio de predicción de los especialistas médicos fue del 82%. Esta discrepancia sugiere que el sistema supera ligeramente a la evaluación realizada por los especialistas, 53% sobre 47% en el promedio general (Figura 22), lo que indica un alto nivel de eficacia en la detección de la enfermedad. Sin embargo, es importante tener en cuenta que la evaluación de los especialistas se basa en su experiencia clínica y conocimientos especializados, mientras que el sistema se basa en algoritmos y procesamiento de imágenes.

El contraste de los datos obtenidos en este proyecto con los de investigaciones relacionadas es un paso crucial en la validación y contextualización de los hallazgos. En el ámbito de la investigación científica, la comparación con estudios previos proporciona una perspectiva integral y permite evaluar la originalidad y relevancia de los resultados obtenidos. En este sentido, al analizar y contrastar las métricas obtenidas con otros autores, se pueden extraer conclusiones significativas sobre la efectividad y el impacto de mi enfoque metodológico en la predicción de osteoartritis mediante visión por computador. Es importante destacar que este proceso no solo fortalece la validez de los resultados obtenidos, sino que también contribuye al avance del conocimiento en el campo al identificar áreas de convergencia y divergencia entre diferentes enfoques y metodologías de investigación.

Al observar los resultados, se destaca que mi modelo logra una precisión notablemente alta del 93%, superando significativamente los valores de precisión obtenidos por (Tiulpin et al., 2018), en donde se entrenó una red neuronal convolucional con 5960 imágenes de rayos X de rodillas y del cual se obtuvo una precisión media de 66.77%. Asimismo, (Tiulpin et al., 2019) utilizó 3918 imágenes para validar su modelo de predicción multimodal obteniendo una precisión promedio de 68%. Esta discrepancia sugiere que mi enfoque metodológico, la selección de características, el procesamiento de imágenes y la elección del modelo son efectivos y prometedores en comparación con los métodos utilizados por los autores previos.

Los hallazgos obtenidos en este estudio sugieren que el enfoque de utilizar visión por computadora y algoritmos avanzados de procesamiento de imágenes puede ofrecer una contribución significativa a la mejora del diagnóstico de osteoartritis en personas de media y tercera edad, debido a la capacidad de analizar grandes cantidades información e incluso detalles que son imperceptibles al ojo humano, mitigando la subjetividad del diagnóstico tradicional (Tiulpin et al., 2018), confirmando así la validez de la hipótesis planteada.

CONCLUSIONES

La elección de un modelo de inteligencia artificial adecuado es fundamental para el análisis de imágenes, especialmente en el contexto del diagnóstico de osteoartritis mediante visión por computadora. A lo largo de este estudio, se evaluaron diversos modelos de inteligencia artificial, considerando factores clave como precisión, rendimiento y escalabilidad. Los resultados obtenidos destacan la importancia de seleccionar cuidadosamente el modelo más apropiado para la tarea específica fue MobilenetV2, ya que esto puede influir significativamente en la efectividad y el éxito del proceso de diagnóstico asistido por computadora, mejorar la precisión de las predicciones, optimizar el rendimiento del sistema y garantizar su escalabilidad para su aplicación en entornos clínicos y médicos.

En este estudio, se realizó un proceso de entrenamiento exhaustivo con datos clínicos relevantes para la osteoartrosis, para desarrollar un modelo preciso y confiable para detectar la enfermedad. Los resultados demuestran que la implementación adecuada del modelo de inteligencia artificial con datos clínicos específicos puede generar un sistema de diagnóstico asistido por computadora eficaz, pasando de 31 a 93 en el índice de precisión y de 30% a 89 % para predecir correctamente la osteoartrosis en las imágenes de rayos X.

Se llevó a cabo un proceso detallado de diseño de la arquitectura de la aplicación web, centrándose en establecer una conexión fluida y eficiente entre la interfaz de usuario y el modelo de inteligencia artificial subyacente. Los resultados obtenidos muestran que un diseño bien planificado y estructurado de la arquitectura de la aplicación web puede mejorar la usabilidad, la accesibilidad y la funcionalidad del sistema en su conjunto.

Al desarrollar un modelo basado en visión por computadora y aplicar algoritmos avanzados de procesamiento de imágenes, se logró alcanzar una precisión del 93% en la detección de osteoartritis, superando significativamente los valores obtenidos por métodos convencionales y estudios previos. Asimismo, se pudo mejorar la métrica de validación Accuracy que inicialmente era del 30% y que final obtuvo 89%, mejorando la capacidad de predecir correctamente la presencia o ausencia de osteoartrosis. Este

aumento de precisión demuestra la efectividad de la metodología propuesta para identificar la enfermedad, lo que respalda la idea de que el uso de técnicas avanzadas de análisis de imágenes puede mejorar sustancialmente el diagnóstico.

El sistema desarrollado para detectar osteoartritis en imágenes de rayos X muestra una eficacia superior a la evaluación de los especialistas médicos. Con una tasa de aciertos del 94%, el sistema supera significativamente el promedio de predicción de los especialistas, que fue del 82%. Estos resultados sugieren que el sistema puede ser una herramienta útil y precisa para el diagnóstico asistido por computadora en el ámbito de la osteoartritis.

RECOMENDACIONES

Es importante que futuras investigaciones y aplicaciones en el campo de la detección de osteoartritis mediante visión por computadora consideren cuidadosamente la selección del modelo de inteligencia artificial más adecuado para sus necesidades específicas. Esto implica una evaluación exhaustiva de diferentes modelos, considerando sus ventajas y limitaciones en cuanto a precisión, rendimiento y escalabilidad. Además, se recomienda explorar continuamente el desarrollo de nuevos modelos y técnicas de aprendizaje automático para mantenerse al día con los avances en este campo en constante evolución.

La implementación de modelos de inteligencia artificial aplicada al campo de la medicina debe estar estrictamente relacionada a conjunto de datos clínicos relevantes y específicos. Esto implica recopilar y usar datos clínicos de alta calidad y precisión, representativos de la población objetivo y abarquen varios casos de osteoartrosis o de cualquier otra índole o caso de estudio. Además, se recomienda prestar atención a la calidad del proceso de entrenamiento, incluida la selección adecuada de algoritmos, la optimización de hiperparámetros y la validación cruzada para garantizar la generalización y la robustez del modelo.

Se recomienda seguir las mejores prácticas de diseño de interfaces de usuario para garantizar una experiencia de usuario intuitiva y satisfactoria. Al diseñar la arquitectura de la aplicación web de manera cuidadosa, se pueden crear sistemas más robustos y efectivos para la implementación de modelos de inteligencia artificial en entornos prácticos y del mundo real.

Se sugiere integrar el sistema desarrollado como una herramienta complementaria en la práctica clínica de los especialistas médicos. Esto permitiría aprovechar la precisión y eficacia del sistema para mejorar la detección temprana y el diagnóstico de la osteoartritis en entornos médicos reales. Sin embargo, también se recomienda mantener la evaluación y supervisión por parte de los especialistas, utilizando su experiencia clínica y conocimientos especializados para complementar la precisión del sistema. Al combinar ambos enfoques, se puede lograr una atención médica más completa y precisa para los pacientes con osteoartritis, mejorando así su calidad de vida y resultados de tratamiento.

REFERENCIAS

- Alejandro Roca, K. V. (2021). Sistema de detección de personas y cálculo de distancias euclidianas mediante el uso de redes neuronales convolucionales integrando OpenCV y CUDA para medir el índice de cumplimiento del distanciamiento social de los estudiantes de la EEB Lcda. Angélica Villón Lindao. [bachelorThesis, La Libertad: Universidad Estatal Península de Santa Elena, 2021]. <https://repositorio.upse.edu.ec/handle/46000/6484>
- Boutalline, M., Tannouche, A., Faouzi, H., Ouanan, H., & Dargham, M. (2022). Automatic Detection and Classification of Apple Leaves Diseases Using MobileNet V2. *Revue d'Intelligence Artificielle*, 36(5), 745-751. Scopus. <https://doi.org/10.18280/ria.360512>
- Car, Z., Anđelić, N., Lorencin, I., Musulin, J., Štifanić, D., & Baressi Šegota, S. (2021). APPLICATION OF ARTIFICIAL INTELLIGENCE-BASED IMAGE ANALYSIS IN BIOINFORMATICS. *Book of Proceedings: 1st International Conference on Chemo and BioInformatics*, 47-54. <https://doi.org/10.46793/ICCBI21.047C>
- Django. (2024). Django Project. <https://www.djangoproject.com/>
- González, F. A. (2015). Modelos de aprendizaje computacional en reumatología. *Revista Colombiana de Reumatología*, 22(2), 77-78. <https://doi.org/10.1016/j.rcreu.2015.06.001>
- Google Colaboratory. (2024). <https://colab.research.google.com/>
- IGM. (2017). Geoportal Ecuador – Infraestructura de Datos Espaciales. <https://www.geoportaligm.gob.ec/portal/>
- Kaggle. (2024). Datasets Documentation. <https://www.kaggle.com/docs/datasets>
- López-González, R., Sánchez-García, J., & García-Castro, F. (2021). Inteligencia artificial en las enfermedades respiratorias. *Archivos de Bronconeumología*, 57(2), 77-78. <https://doi.org/10.1016/j.arbres.2019.12.037>
- Malavé Rosales, V. S. (2022). Datamart para la toma de decisiones en los procesos de evaluación institucional de la Universidad Estatal Península De Santa Elena

- [masterThesis, La Libertad: Universidad Estatal Península de Santa Elena, 2022.].
<https://repositorio.upse.edu.ec/handle/46000/8980>
- Morales Muñoz, L., Quintana, G., & Niño, L. F. (2015). Modelo computacional para la identificación de endofenotipos y clasificación de pacientes con artritis reumatoide a partir de datos genéticos, serológicos y clínicos, utilizando técnicas de inteligencia computacional. *Revista Colombiana de Reumatología*, 22(2), 90-103. <https://doi.org/10.1016/j.rcreu.2015.05.005>
- Nagamani, G. M., & Sudhakar, T. (2023). Automated classification of age-related macular degeneration from optical coherence tomography images using deep learning approach. *IAES International Journal of Artificial Intelligence*, 12(4), 2011-2021. Scopus. <https://doi.org/10.11591/ijai.v12.i4.pp2011-2021>
- NVidia. (2023, diciembre 18). ¿Qué es CUDA? NVIDIA.
<https://support.nvidia.eu/hc/es/articles/4850516229266>
- Pouly, M., Koller, T., Gottfrois, P., & Lionetti, S. (2020). Artificial intelligence in image analysis-fundamentals and new developments. *Der Hautarzt*, 71(9), 660-668. <https://doi.org/10.1007/s00105-020-04663-7>
- ¿Qué es Django? (2024). Amazon Web Services, Inc. <https://aws.amazon.com/es/what-is/django/>
- Quezada Balón, P. M., & Camatón Tomalá, J. A. (2019). Factores biológicos que inciden en el desarrollo de la artrosis primaria en adultos centro de salud San Judas Tadeo, Salinas 2019. [bachelorThesis, Universidad Estatal Península de Santa Elena. 2019]. <https://repositorio.upse.edu.ec/handle/46000/5102>
- Sajda, P. (2006). Machine learning for detection and diagnosis of disease. *Annual Review of Biomedical Engineering*, 8, 537-565.
<https://doi.org/10.1146/annurev.bioeng.8.061505.095802>
- Skansi, S., & Skansi, S. (2018). Convolutional Neural Networks. 121-133.
https://doi.org/10.1007/978-3-319-73004-2_6
- Solis Cartas, U., de Armas Hernandez, A., & Bacallao Carbonell, A. (2014). Osteoarthritis. Características sociodemográficas. *Revista Cubana de Reumatología*, 16(2), 97-103.

- Solis Cartas, U., Prada Hernández, D. M., Molinero Rodríguez, C., de Armas Hernández, A., García González, V., & Hernández Yane, A. (2015). Rasgos demográficos en la osteoartritis de rodilla. *Revista Cubana de Reumatología*, 17(1), 32-39.
- TensorFlow. (2024). TensorFlow. <https://www.tensorflow.org/?hl=es-419>
- Tiulpin, A., Klein, S., Bierma-Zeinstra, S. M. A., Thevenot, J., Rahtu, E., Meurs, J. van, Oei, E. H. G., & Saarakkala, S. (2019). Multimodal Machine Learning-based Knee Osteoarthritis Progression Prediction from Plain Radiographs and Clinical Data. *Scientific Reports*, 9(1), 20038. <https://doi.org/10.1038/s41598-019-56527-3>
- Tiulpin, A., Thevenot, J., Rahtu, E., Lehenkari, P., & Saarakkala, S. (2018). Automatic Knee Osteoarthritis Diagnosis from Plain Radiographs: A Deep Learning-Based Approach. *Scientific Reports*, 8(1), 1727. <https://doi.org/10.1038/s41598-018-20132-7>
- Tomalá Guaranda, A. D. (2021). Implementación de software para la detección de rostros sin mascarillas mediante el entrenamiento de un modelo de inteligencia artificial y visión por computadora en los laboratorios de informática [bachelorThesis, La Libertad: Universidad Estatal Península de Santa Elena, 2021]. <https://repositorio.upse.edu.ec/handle/46000/6494>
- Vidal Fuentes, J. (2021). Artrosis y dolor: La complejidad e impacto de un síntoma. *Revista de la Sociedad Española del Dolor*, 28, 1-3. <https://doi.org/10.20986/resed.2021.3886/2021>
- Vrigazova, B. (2021). The Proportion for Splitting Data into Training and Test Set for the Bootstrap in Classification Problems. *Business Systems Research Journal*, 12(1), 228-242.
- Welcome to Python.org. (2024, febrero 29). Python.Org. <https://www.python.org/>
- Yick, H. T. V., Chan, P. K., Wen, C., Fung, W. C., Yan, C. H., & Chiu, K. Y. (2022). Artificial intelligence reshapes current understanding and management of osteoarthritis: A narrative review. *Journal of Orthopaedics, Trauma and*

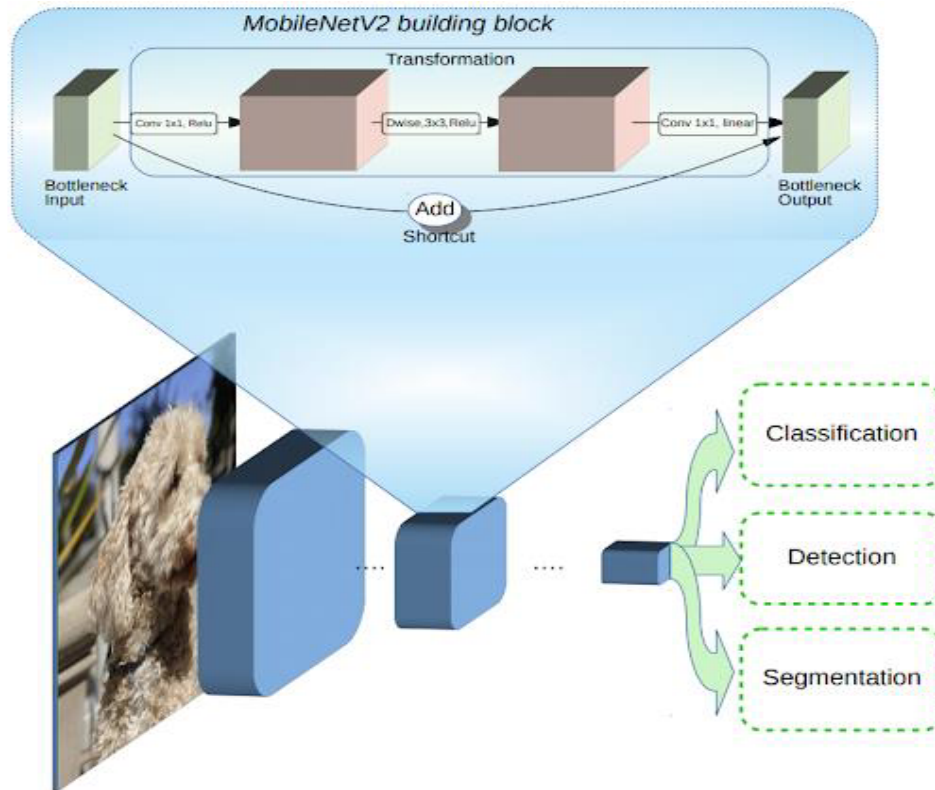
Rehabilitation, 29(1), 22104917221082315.

<https://doi.org/10.1177/22104917221082315>

ANEXOS

Anexo 1: Arquitectura de MobilenetV2

Figura 23. Arquitectura de MobilenetV2



MobileNetV2 es una arquitectura de red neuronal convolucional (CNN) diseñada específicamente para aplicaciones de clasificación de imágenes en dispositivos móviles y embebidos que tienen recursos computacionales limitados. Desarrollada por Google, esta arquitectura representa una mejora con respecto a su predecesora, MobileNetV1. La estructura fundamental de MobileNetV2 se basa en bloques de construcción conocidos como Bloques de Inversión Residual. Estos bloques consisten en una secuencia de capas convolucionales, iniciando y finalizando con capas lineales (convolución 1x1). El diseño de estos bloques está optimizado para preservar la representación de la información y reducir el costo computacional.

Una característica distintiva de MobileNetV2 es su uso de conexiones residuales, las cuales facilitan el entrenamiento de redes más profundas al permitir que la información fluya a través de las capas sin sufrir alteraciones significativas. La arquitectura también hace uso de capas convolutivas separables en lugar de convoluciones estándar, dividiendo la etapa de convolución en dos pasos: una convolución espacial y una convolución en el canal. Esto contribuye a reducir el costo computacional de la red sin comprometer su capacidad de aprendizaje.

Anexo 2: Métricas de Evaluación

Figura 24. Ejemplo de matriz de confusión

		PREDICTED		Total
		Positive (1)	Negative (0)	
ACTUAL	Classes			
	Positive (1)	TP = 20	FN = 5	25
	Negative (0)	FP = 10	TN = 15	25
Total		30	20	50

Figura 25. Fórmulas de métricas de evaluación

$$Precision = \frac{TP}{TP + FP}$$


$$Recall = \frac{TP}{TP + FN}$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

$$F1\text{-Score} = \left(\frac{2}{precision^{-1} + recall^{-1}} \right) = 2 \cdot \left(\frac{precision \cdot recall}{precision + recall} \right)$$

Anexo 3: Interfaz de usuario







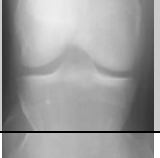

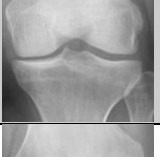

Figura 26. Interfaz de Usuario









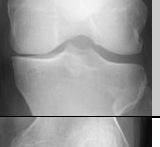



Powered by [he-llo AI](#)

La figura anterior muestra el resultado de la interfaz de usuario destinado para la predicción de osteoartritis, con aspecto minimalista y funcionalidad de pocos pasos, donde el usuario puede arrastrar una imagen directamente en el recuadro o seleccionar desde el explorador de archivos. Luego de presionar en el botón Predecir, la imagen cargada en el navegador es enviada en base64 hacia el microservicio de predicción donde es reconstruida y analizada, para luego retornar una respuesta al frontend con los índices de predicción que pueden visualizarse en el gráfico de anillos.

Anexo 4: Evaluación de especialistas

Imagen	EI	EV1	P1	EV2	P2	EV3	P3	EV4	P4	EV5	P5	TEV	TP
	0	0	0	0	0	0	0	0	0	0	0	5	5
	0	0	0	1	0	0	0	0	0	0	0	4	5
	0	0	0	0	0	0	0	1	1	0	0	4	4
	0	1	1	0	0	0	0	0	0	0	0	4	4
	0	0	0	0	0	0	0	1	0	0	0	4	5
	0	0	0	0	0	1	1	0	0	0	0	4	4
	0	0	0	0	0	1	0	0	0	0	0	4	5
	0	0	0	0	0	0	0	0	0	0	0	5	5
	0	0	0	0	0	0	0	1	1	1	1	3	3
	0	0	0	0	0	1	0	0	0	0	0	4	5

	1	0	0	1	1	1	1	0	0	1	1	3	3
	1	1	1	1	1	1	1	1	1	1	1	5	5
	1	1	1	1	1	0	1	1	1	1	1	4	5
	1	1	1	1	1	1	1	1	1	1	1	5	5
	1	1	1	1	1	1	1	1	1	1	1	5	5
	1	1	1	0	1	1	1	1	1	0	0	3	4
	1	1	1	0	0	1	1	0	1	1	1	3	4
	1	1	1	1	1	1	1	1	1	0	0	4	4
	1	1	1	1	1	1	1	0	1	0	0	3	4
	1	0	1	1	1	1	1	1	1	0	1	3	5
TOTAL												82	94

El cuadro anterior muestra los resultados de las predicciones realizadas por los especialistas y el modelo entrenado en este proyecto. Para propósito de evaluación se ha determinado la siguiente nomenclatura:

EI: Etiqueta de imagen, valor de clase cero o uno.

EV#: Diagnostico del evaluador enumerado del 1 al 5, valor de clase cero o uno.

P#: Predicción enumerada del 1 al 5, valor de clase cero o uno.

TEV: Total de evaluaciones correctas.

TP: Total de predicciones correctas.

Los totales corresponden a la suma de valores de clases que coinciden con la etiqueta, dando 82 evaluaciones y 94 predicciones correctas.

Anexo 5: Descripción de la entrevista a especialistas.

1. ¿Cuál es su opinión sobre el uso de la visión por computadora y modelos de inteligencia artificial para predecir la osteoartritis a partir de imágenes de rayos X?

Esta pregunta busca obtener la perspectiva del traumatólogo sobre la viabilidad y utilidad de la inteligencia artificial en el campo de la medicina, específicamente en la predicción de la osteoartritis a partir de imágenes radiográficas. Permite conocer si el traumatólogo considera que esta tecnología puede mejorar el proceso de diagnóstico en comparación con los métodos tradicionales, así como su disposición a adoptar nuevas tecnologías en su práctica clínica.

2. Como traumatólogo, ¿qué características o patrones específicos en las imágenes de rayos X considera más relevantes para predecir la osteoartritis?

Aquí se busca aprovechar la experiencia clínica del traumatólogo para identificar qué características o patrones específicos en las imágenes radiográficas podrían ser indicativos de osteoartritis. Proporciona información sobre los marcadores visuales que los especialistas consideran importantes en el proceso de diagnóstico y puede ayudar a orientar el desarrollo de algoritmos de inteligencia artificial.

3. ¿Cómo cree que un modelo entrenado puede identificar y utilizar eficazmente estos marcadores?

Esta pregunta explora la percepción del traumatólogo sobre cómo un modelo de inteligencia artificial puede ser entrenado para reconocer y aprovechar los marcadores identificados en las imágenes de rayos X. Permite comprender cómo el traumatólogo imagina que la tecnología puede ser utilizada de manera efectiva en la práctica clínica para mejorar el proceso de diagnóstico de la osteoartritis.

4. En su experiencia clínica, ¿cómo imagina que un modelo entrenado podría integrarse en su práctica diaria para mejorar el proceso de diagnóstico y tratamiento de la osteoartritis?

La pregunta anterior busca obtener información sobre cómo el traumatólogo imagina la implementación práctica de un modelo de inteligencia artificial en su rutina clínica. Explora posibles escenarios de uso y cómo la tecnología puede complementar o mejorar el proceso de diagnóstico y tratamiento de la osteoartritis desde la perspectiva del traumatólogo.

5. ¿Qué aspectos específicos considera importantes para garantizar la precisión y fiabilidad de estos modelos en entornos clínicos?

Finalmente, esta pregunta indaga sobre los requisitos y consideraciones que el traumatólogo considera fundamentales para asegurar la precisión y confiabilidad de los modelos de inteligencia artificial en el contexto clínico. Proporciona información sobre los estándares de calidad y seguridad que se esperan en la implementación de esta tecnología en entornos médicos.