

Análisis Comparativo de Herramientas de Inteligencia Artificial para el Desarrollo de Plataformas de Diagnóstico por Imágenes Médicas de Enfermedades Respiratorias.

Comparative Analysis of Artificial Intelligence Tools for the Development of Medical Imaging-Based Diagnostic Platforms for Respiratory Diseases

Recibido: 13 Septiembre de 2024

Aprobado: 21 Diciembre de 2024

Cómo citar: D. C. Candia-Herrera, K. Y. Sánchez-Mojica, A. J. Contreras-Rodriguez, D.A. Beltrán-Reyes , J. D. Rico-Echeverri, "Análisis Comparativo de Herramientas de Inteligencia Artificial para el Desarrollo de Plataformas de Diagnóstico por Imágenes Médicas de Enfermedades Respiratorias," *Mundo Fesc*, vol. 15, no. 31, 2025, doi: 10.61799/2216-0388.1819.

Diana Carolina Candia-Herrera^{1*}



Magister en Educación, Corporación Universitaria Iberoamericana, Grupo de Investigación GIGCIC, diana.candia@docente.ibero.edu.co, Colombia, <https://orcid.org/0000-0001-8934-8756>

Karla Yohana Sánchez-Mojica²



Magister en Ingeniería Industrial, Corporación Universitaria Iberoamericana, Grupo de Investigación GIGCIC, diana.candia@docente.ibero.edu.co, Colombia, <https://orcid.org/0000-0003-3164-4725>

Ana Yesmit Contreras-Rodriguez³



Esp-M.Sc Sistemas sostenibles de producción.
jfhoysp@ufpso.edu.co
<https://orcid.org/0000-0002-0377-4664>
Docente asociado Universidad Francisco de Paula Santander Ocaña, Ocaña, Colombia

Diego Alejandro Beltrán-Reyes⁴



Estudiante Ingeniería de Software 7° semestre, Corporación Universitaria Iberoamericana, dbeltr38@estudiante.ibero.edu.co, Colombia, <https://orcid.org/0009-0001-2991-192X>

Jhonatan David Rico-Echeverri⁵



Estudiante Ingeniería de Software 7° semestre, Corporación Universitaria Iberoamericana, jrcoech@estudiante.ibero.edu.co, Colombia, <https://orcid.org/0009-0002-9857-3052>

*Autor para correspondencia:

diana.candia@docente.ibero.edu.co



Análisis Comparativo de Herramientas de Inteligencia Artificial para el Desarrollo de Plataformas de Diagnóstico por Imágenes Médicas de Enfermedades Respiratorias.

Palabras clave: COVID-19, Diagnóstico por imágenes médicas, Inteligencia artificial, Neumonía bacteriana, Tuberculosis.

Resumen

Las enfermedades respiratorias por virus y bacterias, como COVID-19, neumonía bacteriana y tuberculosis representan una amenaza para la salud pública en general, especialmente en contextos donde el acceso a herramientas médicas de alta tecnología es limitado. En este sentido, la inteligencia artificial ha sobresalido como una herramienta clave para optimizar el diagnóstico por imágenes médicas, mejorando la precisión y reduciendo los tiempos de atención. El objetivo general de esta investigación fue identificar, caracterizar y comparar herramientas tecnológicas que faciliten el desarrollo de plataformas de diagnóstico de enfermedades respiratorias mediante la IA. Se utilizó una metodología de tipo descriptivo con enfoque cualitativo, estructurada en cuatro etapas: revisión documental, clasificación de herramientas, diseño de una matriz comparativa y evaluación cualitativa, generando una ruta crítica de selección. Los resultados permitieron identificar herramientas como Python, Tensor Flow, ChestX-ray8, ONNX, Pydicom, Flask/FastAPI, las cuales mostraron ventajas en términos de rendimiento, compatibilidad, escalabilidad y accesibilidad. Estas herramientas ofrecen una base sólida para el desarrollo de plataformas de diagnóstico automatizado, destacando especialmente en entornos clínicos con recursos limitados. Esta investigación aporta una guía validada y consecuente para la selección de herramientas tecnológicas en proyectos de soluciones médicas, contribuyendo al desarrollo de software de uso clínico robustos, escalables y éticamente responsables.

Comparative Analysis of Artificial Intelligence Tools for the Development of Medical Imaging- Based Diagnostic Platforms for Respiratory Diseases

Abstract

Respiratory diseases caused by viruses and bacteria, such as COVID-19, bacterial pneumonia, and tuberculosis, pose a significant threat to public health, particularly in contexts where access to high-tech medical tools is limited. In this regard, artificial intelligence has emerged as a key tool to optimize medical imaging diagnostics, improving accuracy and reducing response times. The general objective of this study was to identify, characterize, and compare technological tools that facilitate the development of diagnostic platforms for respiratory diseases through AI. A descriptive methodology with a qualitative approach was employed, structured in four stages: literature review, tool classification, design of a comparative matrix, and qualitative evaluation, leading to the development of a critical selection pathway. The results allowed the identification and prioritization of tools such as Python, TensorFlow, ChestX-ray8, ONNX, Pydicom, and Flask/FastAPI, which demonstrated advantages in terms of performance, compatibility, scalability, and accessibility. These tools provide a solid foundation for the development of automated diagnostic platforms, particularly in clinical environments with limited resources. This research offers a validated and consistent guide for the selection of technological tools in medical solution projects, contributing to the development of robust, scalable, and ethically responsible clinical software.

Keywords: Artificial intelligence, Bacterial pneumonia, COVID-19, Medical imaging diagnostics, Tuberculosis.

Introducción

El propósito de este artículo es analizar y comparar las herramientas disponibles para el desarrollo de una plataforma de reconocimiento de imágenes médicas enfocada en la detección de enfermedades respiratorias infecciosas causadas tanto por virus como por bacterias. Específicamente, se consideran patologías como el COVID-19, neumonía bacteriana y tuberculosis, utilizando inteligencia artificial como base tecnológica para mejorar la precisión y eficiencia en el diagnóstico.

El procesamiento de imágenes médicas desempeña un papel crucial en la detección temprana de enfermedades respiratorias. Es por esto por lo que, la inteligencia artificial ha aparecido como una herramienta clave para mejorar los procesos, permitiendo analizar un mayor número de imágenes en menor tiempo y con mayor precisión [1],[18].

Por otro lado, en el desarrollo de software es esencial seleccionar las herramientas adecuadas que permitan alcanzar los objetivos planteados. Teniendo en cuenta la gran variedad de opciones disponibles para la creación de la plataforma, es necesario caracterizarlas con el fin de clasificarlas y seleccionarlas a partir de las ventajas y desventajas de cada una, para asegurar que la plataforma se construya con la tecnología más apropiada. Estudios recientes han indicado que los algoritmos de IA aplicados a radiografías de tórax pueden alcanzar una precisión diagnóstica comparable a la de los profesionales de la salud en la identificación de neumonía [2].

Para ello, se llevó a cabo una búsqueda preliminar de herramientas alineadas con los requerimientos del proyecto, obteniendo la identificación inicial de treinta herramientas relacionadas, directa e indirectamente, con el desarrollo de la plataforma. Aunque el equipo de investigación tenía conocimientos previos sobre algunas de ellas, fue necesario realizar un análisis más profundo; luego, para organizar y evaluar esta información, se diseñó una matriz comparativa que permitió describir y clasificar cada herramienta según sus características clave, con este análisis se adecuó una guía para la selección de herramientas tecnológicas para el desarrollo de plataformas de reconocimiento de imágenes médicas.

Para esta exploración, se tuvo como base la metodología investigativa, donde se realizó una revisión a fondo de literatura científica e información técnica relevante, analizando herramientas utilizadas con anterioridad en el desarrollo de software médico. Los criterios de selección incluyeron, relevancia para la plataforma, capacidades técnicas, facilidad de implementación, requerimientos de la herramienta, costos y accesibilidad, soporte y documentación, compatibilidad con otras herramientas, entre otros.

Los resultados de esta investigación proporcionan una guía sustentada para la selección de las herramientas tecnológicas para el desarrollo de la plataforma, destacando

aquellas que ofrecen mejores beneficios, en cuanto al lenguaje de programación y el uso de inteligencia artificial, por ejemplo, Python [13], incluyendo algunas de sus bibliotecas como Pydicom y PyTorch, entre otras. Este trabajo contribuye a la selección de tecnologías orientadas a diagnósticos más rápidos y precisos en la detección de enfermedades respiratorias infecciosas causadas por virus y bacterias.

Marco Teórico

1. Enfermedades Respiratorias Infecciosas:

Las enfermedades respiratorias de carácter infeccioso como lo son la neumonía, el COVID 19 y la tuberculosis, son un problema de salud bastante grave en todo el mundo, siendo la primera de estas una de las principales causas de muerte por infección respiratoria, donde las víctimas, en su mayoría, son menores de cinco años; anualmente se registran más de 8 millones de pacientes con tuberculosis en todo el mundo y en cuanto al COVID 19, el número de casos activos puede variar dependiendo el momento y región que se observe [19]. Estas enfermedades amenazan significativamente el bienestar en países subdesarrollados, ya que en ellos se dificulta un diagnóstico en un tiempo prudente y el acceso a una atención oportuna [3].

Estas enfermedades desafían considerablemente la salud mundial, en especial en los países donde el acceso a la tecnología médica avanzada, personal capacitado y diagnósticos rápidos es limitado. La demora en la detección y tratamiento de estas enfermedades pueden derivar en complicaciones severas o incluso en el fallecimiento del paciente.

Incorporar nuevas tecnologías se ha convertido no solo en una estrategia prometedora para mejorar los procesos diagnósticos, sino en una necesidad propia del área de la salud, para fortalecer estos procesos con herramientas automatizadas que permitan agilizar y hacer más accesibles los dictámenes clínicos.

2. Inteligencia Artificial Aplicada A las Imágenes Médicas:

La inteligencia artificial ha demostrado ser una buena alternativa para apoyar los diagnósticos clínicos, particularmente en el reconocimiento de imágenes médicas, para ello ya se ha venido implementando en la rama de la medicina y con ayuda de la ingeniería, tecnologías de aprendizaje profundo, definidas como “ un subconjunto del aprendizaje automático y, por extensión, de la inteligencia artificial: una técnica de entrenamiento de computadoras que imita la manera en que las neuronas del cerebro humano procesan y recopilan información; es, literalmente, una red neuronal artificial;”, estas se han utilizado en el análisis de radiografías de tórax para detectar anomalías, con el fin de realizar un diagnóstico preciso en el menor tiempo posible. [5], teniendo como objetivo principal en la imagenología, el análisis de las imágenes para generar un diagnóstico.

Particularmente en el campo del diagnóstico por imágenes, la IA ha demostrado un potencial significativo en la identificación automatizada de anomalías en radiografías, tomografías y resonancias magnéticas. Este enfoque no solo mejora la eficiencia del proceso clínico, sino que también reduce el margen de error asociado a la interpretación humana, permitiendo diagnósticos más precisos y oportunos, incluso en contextos donde el personal médico especializado es escaso [6].

3. Clasificación de Imágenes con redes Neuronales Convolucionales (CNN)

Una de las técnicas más empleadas es el modelo de clasificación de imágenes conocidos como CNN (modelos de programación potentes que permiten principalmente el reconocimiento de imágenes atribuyendo automáticamente a cada imagen proporcionada en la entrada, una etiqueta correspondiente a la clase a la que pertenece [7], logrando resultados positivos frente a la clasificación correcta de imágenes con enfermedades respiratorias. No obstante, es importante precisar que adicional a la tecnología y modelos elegidos para el desarrollo correcto de la lectura de imágenes, se debe tener una adecuada selección de las herramientas de desarrollo, pues de ellas depende en gran parte la eficacia de la plataforma.

Estas redes, son utilizadas para el procesamiento de imágenes, voz, audio y vídeo, siendo una de las herramientas con mejores resultados en el reconocimiento de patrones, Las CNN hacen parte del aprendizaje supervisado, su importancia proviene de la similitud con el modo de aprendizaje humano, la estructura de las redes neuronales está compuesta por los siguientes elementos: entrada, convolución, pooling, ReLU, una capa totalmente conectada y al final la capa de salida, [8].

A continuación, se explicará brevemente cada una de las capas del modelo de clasificación de imágenes: la primera es la capa de entrada que corresponde a la imagen que se desea analizar, la convolución, como segunda capa, es el elemento más básico de la CNN donde principalmente se mejora la calidad de la imagen y se empiezan a detectar aspectos significativos en la imagen donde se genera mapas de características, luego en la capa de agrupación o Pooling se reduce el tamaño de los mapas de características para disminuir los parámetros, en la capa de activación (Relu) se sustituyen los valores negativos recibidos por ceros, después en la capa totalmente conectada (FC) se conectan por completo las neuronas de salida, combinando linealmente y clasificando la imagen para finalmente en la capa de salida devolver un vector con cierto número de clases donde cada componente presenta la probabilidad de que la imagen pertenezca a una clase específica. En resumen, de esta forma este modelo permite identificar si una imagen de radiología presenta las características para considerar que se encuentra con alguna enfermedad respiratoria, para el caso de esta investigación.

Las CNN se han usado con éxito en la clasificación de radiografías de tórax para identificar signos de enfermedades respiratorias como la tuberculosis, la neumonía y recientemente el COVID-19. Por ejemplo, el modelo CheXNet desarrollado por [5] alcanzó niveles de

precisión similares a los de médicos radiólogos para la detección de neumonía a partir de las radiografías. Este tipo de herramientas permite automatizar el proceso diagnóstico, aportando velocidad y objetividad al análisis clínico. En la imagen 1 se ejemplifica lo que el modelo CNN realiza para determinar las características de la ilustración de entrada y de esa forma clasificarla, según los parámetros indicados con anterioridad.

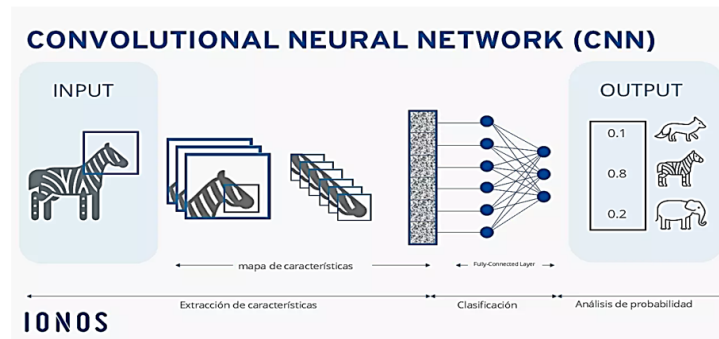


Figura 1. Descripción ejemplificada CNN

4. Sistemas de Soporte a la Decisión Clínica (CDSS)

Los Sistemas de Soporte a la Decisión Clínica (CDSS) son plataformas informáticas que asisten a los médicos en el proceso diagnóstico mediante la integración de información clínica y algoritmos de decisión. Estas soluciones combinan técnicas de inteligencia artificial con bases de conocimiento médico para proporcionar recomendaciones, alertas y sugerencias diagnósticas basadas en evidencia [10]. Los propósitos generales de los CDSS son: responder preguntas, tomar decisiones, optimizar el flujo de trabajo, monitorear las acciones y focalizar la atención.

En el caso de las enfermedades respiratorias, los CDSS que utilizan modelos de clasificación por imágenes, como los basados en CNN, pueden detectar patrones radiológicos específicos, facilitar diagnósticos y contribuir a una gestión clínica más eficiente. Al proporcionar una segunda opinión automatizada, estos sistemas reducen el riesgo de omisiones y mejoran la calidad asistencial.

5. Sistemas Expertos

En el diagnóstico médico, los sistemas expertos se han empleado principalmente para evaluar síntomas clínicos, interpretar signos médicos, y sugerir diagnóstico o tratamientos basados en reglas lógicas y probabilísticas [11]. Aunque con el avance de las tecnologías de procesamiento y lectura de imágenes y el aprendizaje automático, los sistemas expertos han evolucionado hasta llegar a ser capaces de analizar radiografías, tomografías y demás imágenes médicas; esto lo realizan a través de diversas técnicas de razonamiento para emular el proceso de toma de decisiones humanas, adaptándose a los requisitos del dominio específico [12].

En proyectos de salud pública, especialmente en regiones rurales o con limitaciones de infraestructura, la incorporación de sistemas expertos en plataformas diagnósticas permite extender el acceso a decisiones clínicas especializadas, mejorar la igualdad en la atención médica y fortalecer la vigilancia epidemiológica a partir del análisis automatizado de imágenes radiológicas.

6. Herramientas Tecnológicas

Como parte de estas herramientas podemos encontrar varias categorías, a continuación detallamos las más relevantes: para el manejo de imágenes médicas se debe contar con tecnologías que permitan su almacenamiento, visualización y manipulación; para el desarrollo y entrenamiento de modelos IA se deben incluir librerías y frameworks; también es necesario contar con bases de datos que contengan radiografías de tórax ya etiquetadas para las enfermedades respiratorias de carácter infeccioso; así mismo contar con una infraestructura para el despliegue preferiblemente en la nube o servicios locales que permitan procesar grandes volúmenes de datos, en cuanto al desarrollo de la plataforma, se debe contar con herramientas para la construcción de la interfaz y el back-end que cumplan con los estándares y las normas éticas y legales; por último, se deben incluir librerías que evalúen el rendimiento del modelo con métricas médicas específicas que se puedan corroborar, algunas de ellas son:

- **Frameworks de Aprendizaje Profundo:** Tensor Flow, PyTorch son los frameworks más utilizados para el desarrollo de modelos de aprendizaje profundo. Ofrecen funciones para la construcción de redes neuronales, entrenamiento eficiente y herramientas para la visualización del proceso de aprendizaje.
- **Librerías Especializadas:** OpenCV permite la manipulación de imágenes médicas; Matplotlib y Seaborn permiten la visualización de resultados. Estas librerías contribuyen a una exploración integral de los datos y a una validación precisa del modelo.
- **Bases de Datos Médicas:** Datasets como ChestX-ray14 (NIH), COVIDx (University of Waterloo) y Montgomery County Set (U.S. Department of Health) proporcionan imágenes radiográficas etiquetadas que sirven para entrenar y evaluar modelos de IA. La calidad y representatividad de los datos incide directamente en la capacidad predictiva del modelo [13].
- **Infraestructura de Despliegue:** Para el funcionamiento en producción, se requieren servicios de cómputo como Google Cloud, Amazon Web Services (AWS) o Microsoft Azure, que permiten el procesamiento en la nube, acceso remoto, escalabilidad dinámica y monitoreo continuo del sistema.
- **Herramientas de Desarrollo de Plataforma:** Tecnologías como Flask o FastAPI permiten desarrollar el backend de forma ágil, mientras que frameworks como React o Vue.

js facilitan la creación de interfaces interactivas. Estas herramientas deben cumplir estándares de interoperabilidad y garantizar la privacidad de los datos clínicos conforme a regulaciones actuales.

- **Evaluación del Rendimiento del Modelo:** La validación clínica requiere el uso de métricas específicas como la sensibilidad y la precisión. Librerías como TensorBoard o scikit-learn permiten calcular y visualizar estas métricas, garantizando una evaluación rigurosa del desempeño del modelo.

En consecuencia, se hace necesario considerar criterios específicos como la precisión diagnóstica, la escalabilidad, la accesibilidad tecnológica, y la facilidad de implementación en todo tipo de poblaciones, al seleccionar las herramientas para desarrollar la plataforma aplicada al diagnóstico médico mediante la inteligencia artificial. Por lo tanto, en este estudio se pretende identificar, caracterizar, categorizar, comparar y seleccionar herramientas disponibles para el desarrollo de la plataforma en creación, enfocada en la detección de enfermedades respiratorias por origen de carácter infeccioso, con el fin de establecer una base sólida para una solución tecnológica que contribuya al diagnóstico temprano, preciso y accesible.

Materiales y Métodos

Este estudio adoptó un enfoque descriptivo con orientación cualitativa dirigido a identificar, caracterizar y comparar herramientas tecnológicas para el desarrollo de una plataforma de diagnóstico médico mediante imágenes de radiografías. El análisis se estructuró en cuatro etapas secuenciales:

Etapas 1- **Recolección y revisión documental:** se realizó una revisión exhaustiva de literatura científica, técnica y académica. Las fuentes incluyeron artículos indexados, documentación oficial de desarrollo, repositorios, bases de datos públicas y normativas ISO. La búsqueda se llevó a cabo en bases como SpringerLink, Google Scholar y IEEE. Se identificaron inicialmente 27 herramientas tecnológicas, seleccionadas bajo criterios de inclusión y exclusión definidos.

Criterios de inclusión:

- Herramientas con soporte activo y documentación oficial.
- Uso comprobado en plataformas médicas o de diagnóstico.
- Herramientas de acceso libre / gratuito.
- Compatibilidad con modelos de aprendizaje profundo.

Criterios de exclusión:

- Tecnologías desactualizadas o sin soporte.

- Tecnologías de propiedad privada.
- Ausencia de antecedentes en el contexto de imágenes médicas.
- Incompatibilidad con inteligencia artificial.
- Incumplimiento de normas ISO.

Etapa 2 - Clasificación y descripción de herramientas: las herramientas se agruparon según funcionalidad en cinco categorías: Frameworks de IA, Procesamiento y visualización, modelos pre entrenados, despliegue e integración, y complementarias. Se describieron técnicamente considerando sus capacidades, aplicaciones clínicas y flexibilidad y disponibilidad.

Frameworks IA:

Python: Lenguaje de programación central por su simplicidad, robustez y extensa comunidad científica. Es compatible con todas las herramientas necesarias para el desarrollo de IA médica.

Tensor Flow: Framework de aprendizaje profundo que permite construir modelos de redes neuronales para el análisis de imágenes médicas, con soporte para ejecución en CPU, GPU y Edge.

PyTorch: Alternativa a Tensor Flow, preferida en investigación por su flexibilidad. Es la base de bibliotecas como MONAI.

MONAI (Medical Open Network for AI): Framework sobre PyTorch optimizado para procesamiento de imágenes médicas, incluye funciones específicas para segmentación, clasificación y registro.

Keras: API de alto nivel para redes neuronales, utilizada en conjunto con Tensor Flow. Facilita la construcción rápida de modelos.

Scikit-learn: Biblioteca para aprendizaje automático tradicional. Útil para tareas complementarias como clasificación o reducción de dimensionalidad.

o Inferencia, Despliegue e Integración:

Edge TPU: Procesador de IA en dispositivos locales, usado para ejecutar modelos optimizados en entornos con baja conectividad (zonas rurales).

ONNX: Protocolo de intercambio para modelos de IA entre diferentes frameworks (ej. de PyTorch a Tensor Flow o TFLite).

Visual Studio Code: Entorno de desarrollo ampliamente usado por su capacidad para gestionar proyectos en Python, su integración con Git y su soporte para debugging.

PostgreSQL: Sistema de base de datos relacional, usado para almacenar registros clínicos, resultados del modelo y trazabilidad del diagnóstico.

o Librerías de Procesamiento y Visualización:

OpenCV: Biblioteca de visión por computador usada para el preprocesamiento de imágenes médicas, especialmente en la limpieza y estandarización de radiografías.

SimpleITK: Herramienta para leer, transformar y manipular imágenes médicas multidimensionales (DICOM, NIfTI, etc.).

Pydicom: Librería para manipular archivos DICOM, el estándar de imágenes médicas. Permite extracción de metadatos clínicos.

Matplotlib y Seaborn: Utilizadas para la visualización gráfica de resultados, métricas de evaluación y análisis exploratorios.

XRAI: Algoritmo de interpretabilidad visual que destaca regiones relevantes en imágenes para justificar las decisiones del modelo.

o Arquitectura y Modelos Pre-Entrenados:

MobileNet: Modelo eficiente de clasificación de imágenes, ideal para su uso en dispositivos móviles o de bajo consumo.

VGG16: Arquitectura CNN profunda utilizada como base en múltiples estudios de clasificación de imágenes médicas.

BioMedGPT: Modelo de lenguaje de propósito biomédico, útil para generar explicaciones automáticas o interpretar textos clínicos.

RadBERT: Modelo especializado en texto clínico radiológico, empleado para análisis de reportes médicos y lenguaje natural en salud.

CheXNet: Red convolucional entrenada con más de 100,000 radiografías para detectar 14 patologías torácicas, como neumonía o tuberculosis [5].

ChestX-ray8: Base de datos de radiografías de tórax a escala hospitalaria y puntos de referencia para la clasificación y localización con supervisión débil de enfermedades comunes del tórax [13]

o Complementarias y Especializadas:

Nvidia Clara: Plataforma de desarrollo de IA médica con herramientas para segmentación,

anotación y entrenamiento de modelos en imágenes clínicas.

AI4Health: Repositorio impulsado por la OMS y otras entidades, que ofrece casos de uso, guías y herramientas de IA aplicadas a la salud pública.

WHO COVID-19 Database: Base de datos científica con literatura actualizada sobre COVID-19, útil para análisis de contenido y entrenamiento temático.

DICOM Web Viewer: Herramienta usada para visualizar imágenes DICOM directamente desde plataformas web.

Flask o FastAPI: Frameworks ligeros para construcción de APIs médicas que integran modelos IA en la nube o servidores locales.

Etapa 3 - Diseño de Matriz Comparativa: se diseñó una matriz comparativa con el fin de contrastar las herramientas enlistadas en la etapa inicial, para organizarlas según su servicio. La matriz incluyó información relevante como: criterios de inclusión, criterios de exclusión, compatibilidad, documentación disponible, costos, integración con modelos de aprendizaje profundo y antecedentes de plataformas.

Esta matriz fue esencial para realizar una clasificación inicial por categorías funcionales: frameworks de IA, librerías de procesamiento de imágenes, bases de datos médicas y herramientas de despliegue. En la tabla I se resume la matriz comparativa:

Tabla I. Matriz comparativa

Herramienta	Autor	AÑO	Fuente	Objetivo	Situación Problema	Metodología	Resultado y Conclusión	Palabras clave	Criterios de inclusión o exclusión	Comentario	Enlace	Tipo	Artículo relacionado	Enlace del artículo
	Guido van Rossum	1991	Python.org	Lenguaje base para el desarrollo de IA	Necesidad de un lenguaje flexible para IA en salud	Programación orientada a IA	Soporte para múltiples bibliotecas de IA	Lenguaje, programación, IA	Compatible con bibliotecas de IA y fácil de usar	Fundamental para desarrollo	https://www.python.org/	Gratis	Análisis de imágenes médicas mediante algoritmos de aprendizaje profundo	https://www.frontiersin.org/journals/puhealth/arti389/fpu53/full

Tensor Flow	Google Brain	2015	TensorFlow.org	Frark para entrenamiento de IA	Facilita la implementación de modelos de IA en imágenes médicas	Implementación de CNNs para clasificación	Alto rendimiento en reconocimiento	Redes neuronales, IA, imagen médica	Alto rendimiento y soporte activo	Recomendado para entrenamiento de modelos	https://www.tensorflow.org	Gratis	TensorFlow: la biblioteca de código abierto de Google para acelerar la adopción de la IA	https://www.bbva.com/es/innovacion/tensorflow-la-biblioteca-de-codigo-abierto-de-google-para-acelerar-la-adopcion-de-la-ia/
Py Torch	Meta AI	2016	Pytorch.org	Alternativa flexible a Tensor Flow	Facilita depuración y experimentación en IA	Programación de redes neuronales en Python	Más dinámico y fácil de probar	Deep Learning, IA, imagen médica	Popular en investigación, fácil de modificar	Útil para investigación en IA	https://pytorch.org/	Gratis	Triaje automatizado de radiografías de tórax en adultos con redes neuronales artificiales profundas	https://pubs.rsna.org/doi/full/10.1148/radiol.2018180921

Fuente: Elaboración propia con base en Python.org (1991), TensorFlow.org (2015), Pytorch.org (2016). Source: Authors' elaboration based on Python.org (1991), TensorFlow.org (2015), Pytorch.org (2016).

Etapa 4 - Evaluación cualitativa: las herramientas fueron calificadas asignando un valor entre 1 (bajo) y 3 (alto) según su desempeño por criterio. Posteriormente se obtuvo un puntaje promedio para establecer un ranking categórico.

Tabla II. Criterios de evaluación.

Criterios de Evaluación	Abr	Descripción
Relevancia para la plataforma	CT1	¿Es esencial, complementaria o innecesaria?
Capacidades técnicas	CT2	¿Qué tan bien se adapta a las necesidades de procesamiento de imágenes médicas?
Facilidad de implementación	CT3	¿Es fácil de integrar en la plataforma?
Requerimientos de hardware/software	CT4	¿Tiene dependencias o restricciones técnicas?
Costos y accesibilidad	CT5	¿Es de pago o gratuito? ¿Requiere infraestructura específica?
Soporte y documentación	CT6	¿Cuenta con soporte activo y buena documentación?
Compatibilidad con otras herramientas	CT7	¿Es compatible con otras herramientas en la lista?

Fuente: Elaboración propia con base en literatura científica y normativa ISO (2023). Source: Authors' elaboration based on scientific literature and ISO standards (2023).

Con la matriz y los criterios ya definidos, se llevó a cabo la evaluación cualitativa de las herramientas, para ello se aplicó un análisis de contenido y análisis temático, siguiendo la técnica propuesta por [15]. La valoración se realizó asignando una puntuación por

cada criterio de la siguiente manera:

- 3 puntos (Alta): cumplen ampliamente con el criterio.
- 2 puntos (Media): cumplen de manera aceptable, pero con limitaciones.
- 1 punto (Baja): no cumple o cumple con limitaciones significativas.

Resultados y Discusión

El análisis comparativo permitió identificar, caracterizar y evaluar un conjunto de herramientas tecnológicas relevantes para el desarrollo de la plataforma de diagnóstico médico basada en la inteligencia artificial, enfocada en la evaluación de imágenes de radiografías asociadas a enfermedades respiratorias por virus como el COVID 19 y bacterias como neumonía y tuberculosis.

Luego de aplicar los criterios de inclusión y exclusión, se evaluaron las herramientas, dejando (27) de ellas agrupadas en cinco categorías según su funcionalidad, tal como se informó en la etapa dos de la metodología. Cada una de las herramientas fue evaluada siguiendo los siete criterios indicados en la Tabla II; la calificación se realizó en la escala de 1 a 3, obteniendo un puntaje promedio por cada herramienta.

En la tabla III presentada a continuación, se resume la evaluación por herramienta.

Tabla III. Resultados evaluación

Herramienta	Clasificación	CT1	CT2	CT3	CT4	CT5	CT6	CT7	Avg
Nvidia Clara	Complementarias y Especializadas	3	3	1	3	1	3	1	2,143
WHO COVID-19 Database	Complementarias y Especializadas	3	3	2	3	3	2	3	2,714
AI4Health	Complementarias y Especializadas	3	2	2	1	3	2	3	2,286
DICOM Web Viewer	Complementarias y Especializadas	2	2	3	1	3	2	3	2,286
Flask o FastAPI	Complementarias y Especializadas	3	3	3	1	3	3	3	2,714
ONNX	Despliegue e integración	3	3	2	2	3	3	3	2,714
Visual Studio Code	Despliegue e integración	1	1	3	2	3	2	3	2,143
Edge TPU	Despliegue e integración	2	2	2	3	1	2	2	2,000
PostgreSQL	Despliegue e integración	2	2	2	2	3	3	3	2,429
Python	IA Frameworks	3	3	3	1	3	3	3	2,714
Tensor Flow	IA Frameworks	3	3	2	2	3	3	3	2,714
PyTorch	IA Frameworks	3	3	2	2	3	3	3	2,714
MONAI	IA Frameworks	3	3	2	2	3	3	3	2,714
Keras	IA Frameworks	3	2	3	1	3	3	3	2,571
Scikit-learn	IA Frameworks	2	2	3	1	3	3	2	2,286

MobileNet	Pre-Entrenados	3	2	3	2	3	3	2	2,571
BioMedGPT	Pre-Entrenados	1	1	2	1	3	2	2	1,714
RadBERT	Pre-Entrenados	1	1	2	1	3	2	2	1,714
VGG16	Pre-Entrenados	2	2	2	1	3	2	2	2,000
CheXNet	Pre-Entrenados	3	3	2	2	3	2	2	2,429
ChestX-ray8	Pre-Entrenados	3	3	3	2	3	3	3	2,857
XRAI	Procesamiento y visualización	3	2	2	1	3	2	3	2,286
SimpleTK	Procesamiento y visualización	3	2	2	1	2	2	3	2,143
Pydicom	Procesamiento y visualización	3	2	2	1	3	3	3	2,429
OpenCV	Procesamiento y visualización	2	3	2	1	3	2	2	2,143
Matplotlib	Procesamiento y visualización	2	1	2	1	3	2	2	1,857
Seaborn	Procesamiento y visualización	2	1	2	1	3	2	2	1,857

Fuente: Elaboración propia a partir de la matriz comparativa y criterios de evaluación definidos en la metodología. Source: Authors' elaboration based on the comparative matrix and evaluation criteria defined in the methodology.

El análisis de la Tabla III muestra que herramientas como Python, TensorFlow, PyTorch y MONAI alcanzaron puntajes altos en la mayoría de los criterios, confirmando su relevancia para proyectos de diagnóstico por imágenes médicas. Por el contrario, tecnologías como Edge TPU y BioMedGPT obtuvieron puntajes más bajos debido a limitaciones en infraestructura o a un enfoque distinto al procesamiento de imágenes médicas. Asimismo, se observa que ONNX y Flask/FastAPI destacan en la categoría de integración y despliegue por su capacidad de interoperabilidad y escalabilidad, aspectos clave en entornos hospitalarios donde se requieren soluciones flexibles y adaptables.

En la categoría de Frameworks IA, el promedio general de las herramientas fue mayor que dos, es decir, alto, encontrado que Tensor Flow, Pytorch, Python Y MONAI se posicionan con los mejores promedios, esto debido a su versatilidad, compatibilidad con múltiples librerías y rendimiento en la implementación de redes neuronales convolucionales para el análisis de imágenes médicas, hallazgos que coinciden con estudios recientes de validación clínica basados en transfer learning [19]. En cuanto a Scikit Learn y Keras, obtuvieron una calificación media, siendo útiles para tareas que complementan el objetivo principal, aunque menos especializadas para imágenes médicas.




Figura 2 Resultado evaluación Frameworks IA

No obstante, al revisar el criterio de evaluación número cuatro (requerimientos de hardware/software), en el cual todas las herramientas de la categoría Frameworks IA se encuentran con una calificación por debajo del promedio total, es preciso aclarar, que esto se debe a que su implementación óptima requiere entornos con una capacidad computacional alta, esta necesidad limita su aplicación directa a entornos con recursos tecnológicos reducidos, como hospitales rurales o centros de salud con baja conectividad o sin acceso a hardware especializado.

Para los modelos pre-entrenados, ChexNet y ChestX-ray8 alcanzaron la máxima puntuación, gracias a su validez clínica ya comprobada y el uso en investigaciones recientes y de alto impacto; seguidas por MobileNet, VGG16 y RadBERT que mostraron un buen desempeño, pero aun presentan la necesidad de ajustes para contextos médicos. BioMedGPT obtuvo una calificación más baja, dado a que su enfoque está más orientado al texto médico que a la interpretación o lectura de imágenes.




Figura 3 Resultados evaluación Pre-Entrenados

Como se observa en la (Figura 2), la herramienta ChestX-ray8, en particular, se ha

destacado como la más completa dentro de las analizadas, ya que se trata de una base de datos de imágenes de radiografías de tórax, desarrollada por los Institutos Nacionales de Salud (NIH), la cual contiene más de cien mil radiografías correspondientes a más de treinta mil pacientes, etiquetadas con 14 enfermedades respiratorias. Estas imágenes se encuentran en formato DICOM y ya incluyen anotaciones automáticas extraídas de informes clínicos; su disponibilidad y documentación extensa es fundamental para el entrenamiento de nuevas plataformas. Es decir, que con esta herramienta no solo se conocen datos reales, sino también puede ser la base para la construcción de modelos precisos, escalables y válidos.

Del grupo con las herramientas de procesamiento y visualización, Pydicom y XRAI son las mejores valoradas, la primera es fundamental para el manejo correcto de las imágenes médicas, ya que con ella se realiza la lectura, modificación y procesamiento de archivos en formato DICOM. Incluirla en la plataforma sería esencial para la extracción de datos clínicos y la operabilidad con sistemas médicos existentes; esta es una librería ligera, con mayor documentación y de código abierto, lo cual la hace aún más adecuada. Por otra parte, XRAI se destaca por la interpretación visual, ya que usa mapas de calor para resaltar las regiones relevantes en las imágenes que influyen en la decisión del modelo, al incluirla en la plataforma en desarrollo, se fortalece la explicabilidad del modelo, es decir que quienes interactúen con el desarrollo, comprendan fácilmente el algoritmo y las decisiones.

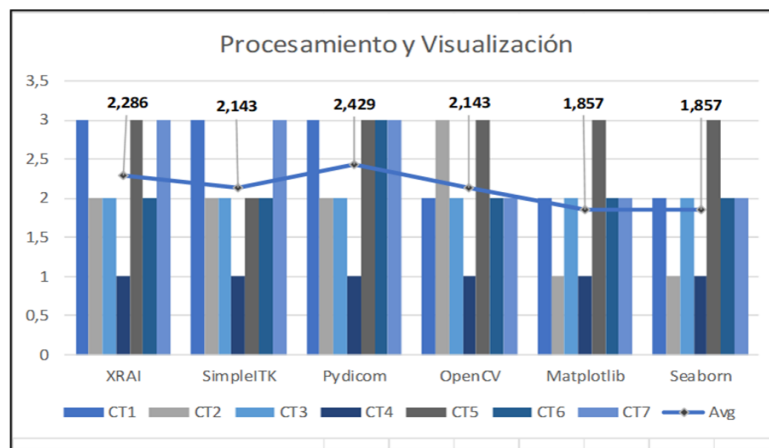


Figura 4 Resultados evaluación Procesamiento y Visualización

Por su parte, OpenCV y SimpleITK obtuvieron calificación media, por la capacidad de realizar operaciones complejas al procesar imágenes, tales como, mejorar contraste, alineación, segmentación o transformación, lo cual es indispensable en las etapas iniciales, donde las imágenes deben ser preparadas para su análisis por las redes neuronales convolucionales.

Con respecto a la clasificación: infraestructura de despliegue e integración, la herramienta "Intercambio abierto de redes neuronales" o ONNX por sus siglas en inglés, obtuvo el

mejor promedio, esta herramienta permite la operabilidad entre diferentes frameworks como Pytorch, Tensor Flow. Esto es esencial para los entornos médicos donde la plataforma deberá adaptarse a diferentes tecnologías sin necesidad de diseñar sistemas desde cero.

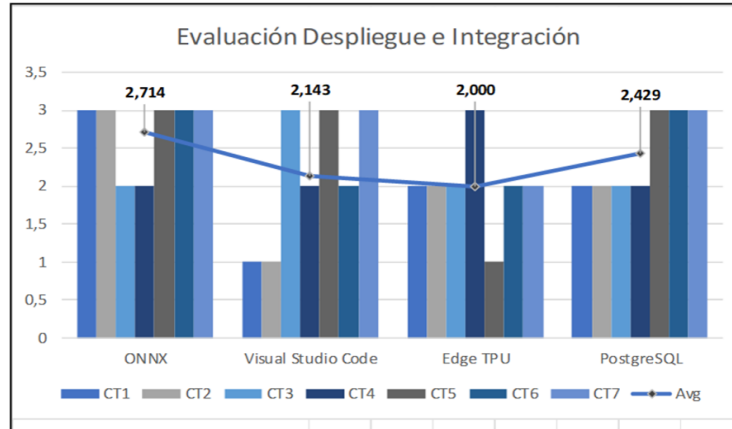


Figura 5 Resultados evaluación despliegue e integración.

Dentro de la categoría complementarias y especializadas, se agruparon herramientas, que, si bien no son la parte central del desarrollo de sistemas, cumplen funciones claves en el procesamiento de imágenes para el diagnóstico clínico, soporte de desarrollo, acceso a datos, validación del sistema, etcétera.

Entre ellas, la herramienta Flask o FastAPI obtuvo una calificación promedio de 2.71, lo que la posicionó como una de las más relevantes en esta categoría. Esta herramienta, permite el desarrollo de interfaces API ligeras, eficientes y seguras, facilitando la comunicación entre el modelo de IA y los diferentes módulos de la plataforma, es esencial para convertir el modelo IA en un servicio funcional con una solución más amplia.




Figura 6 Resultado evaluación complementarias y especializadas

Con la incorporación de herramientas complementarias y especializadas, se fortalece la

usabilidad, flexibilidad y adaptabilidad del sistema en un contexto médico, especialmente donde la conectividad, el personal especializado y/o los recursos son limitados.

Según la evaluación general, las herramientas con mayor calificación son consideradas como prioritarias para el desarrollo de la plataforma en este caso son:

- Python
- Tensor Flow
- Pytorch
- ChestX-ray8
- CheXNet
- Pydicom
- XRAI
- ONNX
- Flask / FastAPI
- MONAI

Estas herramientas ofrecen un equilibrio entre el rendimiento, la escalabilidad, el soporte, la facilidad de integración y el acceso gratuito, lo que las convierte en elementos clave para una plataforma de diagnóstico médico automatizado, confiable y accesible.

Conclusiones

Los hallazgos de este estudio confirman la relevancia y efectividad de herramientas como Python, Tensor Flow, PyTorch, y bases de datos como ChestX-Ray en el desarrollo de plataformas de diagnóstico por medio de imágenes médicas. Estos resultados son coherentes con varios de los estudios donde estas tecnologías se identificaron como esenciales para aplicaciones similares.

Desde una perspectiva operativa, aunque las herramientas priorizadas presentan altos niveles de rendimiento y compatibilidad, algunas requieren infraestructura avanzada, lo que limita su implementación en contextos con recursos limitados como por ejemplo en zonas rurales. Esta situación se ha reportado en investigaciones previas que resaltan la importancia de adaptar modelos y tecnologías a conceptos específicos.

Así mismo, la inclusión de herramientas como XRAI y Pydicom aporta elementos críticos de explicabilidad y seguridad, aspectos fundamentales en entornos clínicos donde la transparencia y la protección de los datos son esenciales. Además, se corrobora desde el enfoque ético, la necesidad de incluir en el desarrollo, los principios de transparencia algorítmica y la toma de decisiones informada, asegurando que los modelos en creación cumplan las normas internacionales y con ello promuevan la aceptación profesional.

Como conclusión, la caracterización y evaluación realizada en este estudio proporcionan una guía robusta y validada para la selección de herramientas tecnológicas en el

desarrollo de plataformas de diagnóstico médico asistido por inteligencia artificial. Las herramientas priorizadas destacan por su rendimiento, escalabilidad, soporte activo, documentación y accesibilidad.

Se recomienda que para investigaciones futuras analicen estas herramientas en entornos con barreras tecnológicas, realizando las validaciones clínicas de forma rigurosa. De igual manera, se propone el diseño de interfaces de usuario para los pacientes como línea de investigación futura, centrándose en la usabilidad y experiencia de usuario en escenarios de salud. Finalmente, se reconoce que la selección de herramientas debe ser flexible, considerando la transformación de los requerimientos, técnicos, clínicos y normativos a lo largo del desarrollo de un proyecto de software.

Referencias

- [1] L. Pinto-Coelho, "How Artificial Intelligence Is Shaping Medical Imaging Technology: A Survey of Innovations and Applications," *Bioengineering*, vol. 10, no. 12, p. 1435, 2023. [Online]. Available: <https://doi.org/10.3390/bioengineering10121435>
- [2] R. L. Cobeñas, M. de Vedia, J. Florez, D. Jaramillo, L. Ferrari, and R. Re, "Rendimiento diagnóstico de algoritmos de inteligencia artificial para detección de compromiso pulmonar por COVID-19 basados en radiografía portátil," *Medicina Clínica*, vol. 160, no. 2, pp. 78–81, 2023. [Online]. Available: <https://doi.org/10.1016/j.medcli.2022.04.016>
- [3] World Health Organization (WHO), "Pneumonia," 2019. [Online]. Available: https://www.who.int/health-topics/pneumonia#tab=tab_1
- [4] ISO, "Aprendizaje profundo: los mecanismos de la magia," [Online]. Available: <https://www.iso.org/es/inteligencia-artificial/aprendizaje-profundo-deep-learning>
- [5] P. Rajpurkar, J. Irvin, R. L. Ball, K. Zhu, B. Yang, H. Mehta, T. Duan, D. Ding, A. Bagul, C. P. Langlotz, B. N. Patel, K. W. Yeom, K. Shpanskaya, F. G. Blankenberg, J. Seekins, T. J. Amrhein, D. A. Mong, S. S. Halabi, E. J. Zucker, A. Y. Ng, and M. P. Lungren, "Deep learning for chest radiograph diagnosis: A retrospective comparison of the CheXNeXt algorithm to practicing radiologists," *PLoS Medicine*, vol. 15, no. 11, pp. e1002686, 2018. [Online]. Available: <https://doi.org/10.1371/journal.pmed.1002686>
- [6] S. Jha and E. J. Topol, "Adapting to artificial intelligence: Radiologists and pathologists as information specialists," *JAMA*, vol. 316, no. 22, pp. 2353–2354, 2016. [Online]. Available: <https://doi.org/10.1001/jama.2016.17438>
- [7] Daniel, "Convolutional Neural Network: definición y funcionamiento," DataScientest, 2023. [Online]. Available: <https://datascientest.com/es/convolutional-neural-network-es>

- [8] F. L. Saca, "Clasificación de imágenes usando redes neuronales convolucionales," Proyecto terminal, Maestría en Ciencias de la Computación, Univ. Autónoma Metropolitana Azcapotzalco, México, 2019.
- [9] IONOS Cloud S.L.U., "Convolutional Neural Network: ¿qué es una red neuronal convolucional (CNN)?," *IONOS Digital Guide*, 2025. [Online]. Available: <https://www.ionos.es/digitalguide/paginas-web/desarrollo-web/convolutional-neural-network/>
- [10] E. H. Shortliffe and J. J. Cimino, *Biomedical Informatics: Computer Applications in Health Care and Biomedicine*, 4th ed. London: Springer, 2014.
- [11] P. Jackson, *Introduction to Expert Systems*, 3rd ed. Reading, MA: Addison-Wesley, 1986.
- [12] D. Candia and Y. Diaz, "Vista de caracterización tecnológica y funcional de los sistemas expertos," *Revista Mundo FESC*, 2024. [Online]. Available: <https://www.fesc.edu.co/Revistas/OJS/index.php/mundofesc/article/view/1612/1173>
- [13] X. Wang, Y. Peng, L. Lu, Z. Lu, M. Bagheri, and R. M. Summers, "ChestX-ray8: Hospital-scale chest X-ray database and benchmarks on weakly-supervised classification and localization of common thorax diseases," in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2017, pp. 3462–3471.
- [14] M. E. Silva Layes, M. A. Falappa, and G. Simari, "Sistemas de soporte a las decisiones clínicas," in *Proc. IV Congreso Argentino de Informática y Salud (CAIS) - JAIIO 42*, 2013. [Online]. Available: https://sedici.unlp.edu.ar/bitstream/handle/10915/93799/Documento_completo.pdf
- [15] V. Braun and V. Clarke, "Using thematic analysis in psychology," *Qualitative Research in Psychology*, vol. 3, no. 2, pp. 77–101, 2006. [Online]. Available: <https://doi.org/10.1191/1478088706QP0630A>
- [16] J. Bustos, "Método de apoyo para el diagnóstico en imágenes radiológicas de neumonía pediátrica mediante técnicas de inteligencia artificial," Tesis de maestría, Univ. El Bosque, Bogotá, 2022. [Online]. Available: <https://repositorio.unbosque.edu.co/items/f2a3f9d2-e273-4fdb-b6f3-8a0ab10ef163>
- [17] M. Palacios and A. Tomalá, "Implementación de una aplicación web para el reconocimiento de patrones de diagnóstico del COVID-19 en rayos X mediante una red neuronal convolucional," Tesis de grado, Univ. Técnica de Cotopaxi, La Maná, 2021. [Online]. Available: <https://repositorio.utc.edu.ec/items/827ad8f1-ed2e-4e6f-b8d4-53c4c08a21b4>
- [18] Y. Akhter, "AI-based radiodiagnosis using chest X-rays: A review," *Frontiers in Big*

Data, vol. 6, art. 1120989, 2023. [Online]. Available: <https://www.frontiersin.org/journals/big-data/articles/10.3389/fdata.2023.1120989/full>

- [19] M. A. Sufian, W. Hamzi, T. Sharifi, S. Zaman, L. Alsadder, E. Lee, A. Hakim, and B. Hamzi, "AI-Driven Thoracic X-ray Diagnostics: Transformative Transfer Learning for Clinical Validation in Pulmonary Radiography," *J. Pers. Med.*, vol. 14, no. 8, art. 856, 2024. [Online]. Available: <https://www.mdpi.com/2075-4426/14/8/856>
- [20] Z. L. Han, et al., "A systematic review and meta-analysis of artificial intelligence assisting the CXR diagnosis of TB," *J. Thorac. Dis.*, 2025. [Online]. Available: <https://jtd.amegroups.org/article/view/100658/html>