

La Inteligencia Artificial en el Diagnóstico Médico

Artificial Intelligence in Medical Diagnosis

Francisco J. Alvarado-Rodríguez^{a*}, Erick E. Guzmán-Quezada^b

^a *Departamento de Electromecánica, Universidad Autónoma de Guadalajara, Av. Patria 1201, Zapopan CP 45129, Jalisco, México, francisco.alvarado@edu.uag.mx*

^b Departamento de Electromecánica, Universidad Autónoma de Guadalajara, Av. Patria 1201, Zapopan CP 45129, Jalisco, México, ercik.guzman@edu.uag.mx

* autor por correspondencia

RESUMEN

La inteligencia artificial (IA) está transformando el diagnóstico médico mediante el uso de técnicas como el aprendizaje automático y las redes neuronales, capaces de analizar imágenes y datos clínicos con una precisión comparable a la de los especialistas. El presente trabajo tiene como objetivo analizar las principales técnicas de IA aplicadas al diagnóstico médico y evaluar sus alcances, limitaciones y desafíos éticos para su integración en la práctica clínica. Para ello, se realizó una revisión de literatura científica reciente (2020–2025) obtenida de Google Scholar, centrada en estudios de aplicación de IA en áreas como oncología, cardiología y oftalmología. Los resultados de la revisión muestran que la IA mejora la precisión diagnóstica y la eficiencia de los procesos clínicos, pero enfrenta barreras importantes relacionadas con la interpretabilidad de los modelos, la privacidad de los datos y la aceptación por parte de los profesionales de la salud. Se concluye que la implementación responsable y ética de la IA será clave para consolidar su papel como herramienta de apoyo en la medicina personalizada y predictiva.

Palabras clave: Inteligencia artificial, Diagnóstico médico, Señales biomédicas, Eficiencia en la atención médica.

ABSTRACT

Artificial intelligence (AI) transforms medical diagnosis by techniques such as machine learning and neural networks, which can analyze images and clinical data with precision comparable to that of specialists. The present work aims to analyze the main AI techniques applied to medical diagnosis and to evaluate their scope, limitations, and ethical challenges for their integration into clinical practice. To this end, a review of recent scientific literature (2020–2025) was conducted using Google Scholar, focusing on studies of AI application in areas such as oncology, cardiology, and ophthalmology. The results of the review show that AI improves diagnostic accuracy and the efficiency of clinical processes, but it faces significant barriers related to model interpretability, data privacy, and acceptance by healthcare professionals. It is concluded that the responsible and ethical implementation of AI will be key to consolidating its role as a support tool in personalized and predictive medicine.

Keywords: Artificial intelligence, Medical diagnosis, Biomedical signals, Healthcare efficiency.

[illegible]

1. Introducción

La inteligencia artificial (IA) se define como la rama de la informática que se centra en el desarrollo de sistemas y algoritmos capaces de realizar tareas que normalmente requieren inteligencia humana (Kaul et al., 2020). Estas tareas incluyen el reconocimiento de patrones, la toma de decisiones, el razonamiento, el aprendizaje y la interacción en lenguaje natural (Bajwa et al., 2021).

En las primeras etapas de su desarrollo, la IA se centraba en la automatización de tareas específicas, utilizando algoritmos básicos y lógica de programación. Por ejemplo, los sistemas expertos, que simulan la toma de decisiones de un humano experto en un dominio particular, eran algunas de las primeras aplicaciones de IA (Muthukrishnan et al. 2020). Sin embargo, estos enfoques tenían limitaciones significativas, ya que dependían en gran medida de reglas fijas y conocimiento explícito, lo que dificultaba su adaptación a situaciones nuevas o inesperadas.

Con la evolución de los algoritmos de aprendizaje automático (machine learning), la IA comenzó a cambiar radicalmente. El aprendizaje automático permite a las máquinas aprender de los datos en lugar de seguir instrucciones predefinidas. Este enfoque ha dado lugar a modelos que pueden identificar patrones y hacer predicciones basadas en ejemplos previos (Mahesh, 2020). La incorporación de técnicas de aprendizaje profundo (deep learning), que se basa en redes neuronales artificiales con múltiples capas, ha sido particularmente impactante. Estas redes son capaces de procesar y aprender de grandes volúmenes de datos no estructurados, como imágenes, texto y audio, y han demostrado resultados sobresalientes en tareas como el reconocimiento de imágenes, la traducción automática y el análisis de sentimientos (Shinde & Shah, 2018).

La evolución de la IA ha sido impulsada por varios factores clave. En primer lugar, el crecimiento exponencial en la capacidad de procesamiento de los ordenadores ha permitido ejecutar algoritmos complejos que requieren un alto poder computacional (Muthukrishnan et al. 2020). La disponibilidad de grandes cantidades de datos también ha sido fundamental; con la creciente digitalización de la información en todos los sectores, se ha generado una cantidad masiva de datos que los modelos de IA pueden utilizar para entrenarse y mejorar su rendimiento. Finalmente, los avances en algoritmos, que incluyen técnicas de optimización y regularización, han permitido a los modelos aprender de manera más eficiente y efectiva (Shinde & Shah, 2018).

Estos desarrollos han llevado a la creación de aplicaciones innovadoras en la medicina, como la detección temprana de enfermedades mediante el análisis de imágenes médicas, la mejora de la precisión en diagnósticos clínicos a través de la interpretación de datos y la optimización de tratamientos personalizados (Bajwa et al., 2021). La medicina es un área que genera enormes volúmenes de datos, que incluyen imágenes médicas, registros electrónicos de salud, resultados de pruebas de laboratorio y datos genómicos. Esta proliferación de datos convierte a la medicina en un campo ideal para el aprovechamiento de la IA, ya que las técnicas avanzadas de análisis de datos pueden procesar y extraer información valiosa que podría pasar desapercibida por el ojo humano.

La capacidad de la IA para procesar grandes volúmenes de datos en tiempo real y extraer patrones complejos permite una mayor eficiencia y precisión en el diagnóstico médico. Esto no solo mejora la precisión de los diagnósticos, sino que también reduce el tiempo que los médicos dedican a tareas administrativas, permitiéndoles concentrarse en la atención directa al paciente (Secinaro et al., 2021). Además, los sistemas de IA pueden aprender y adaptarse continuamente a partir de nuevos datos, mejorando su rendimiento con el tiempo. Esto es especialmente valioso en un campo donde el conocimiento y las prácticas médicas están en constante evolución.

En este contexto, el presente trabajo tiene como objetivo analizar el papel de la inteligencia artificial en el diagnóstico médico, identificando las principales técnicas empleadas, sus beneficios y limitaciones, así como los desafíos éticos y técnicos que condicionan su adopción en la práctica clínica.

2. Materiales y métodos

Para el desarrollo de este trabajo, se realizó una búsqueda de literatura científica a través de Google Scholar, utilizando palabras clave relacionadas con aplicaciones de Inteligencia Artificial en el

diagnóstico médico. La selección de fuentes se enfocó en artículos publicados entre [2020-2025], priorizando revisiones recientes, estudios de caso relevantes, y publicaciones de acceso abierto que permitieran una mejor comprensión del público lector.

2.1 Técnicas de IA en el diagnóstico médico

2.1.1 Aprendizaje Automático (*Machine Learning*)

El aprendizaje automático (ML) es un subcampo de la IA que se centra en el desarrollo de algoritmos que permiten a las computadoras aprender de los datos y hacer predicciones o decisiones basadas en ellos. Se clasifica en varias categorías, como el aprendizaje supervisado, donde los modelos se entrenan con conjuntos de datos etiquetados, y el aprendizaje no supervisado, que busca patrones en datos no etiquetados (Mahesh, 2020). En medicina, el aprendizaje automático se utiliza para predecir la aparición de enfermedades, identificar factores de riesgo y clasificar pacientes (Rong et al., 2020).

2.1.2 Redes Neuronales

Las redes neuronales son modelos computacionales inspirados en la estructura del cerebro humano. Están compuestas por capas de nodos (neuronas) interconectados que procesan datos a través de conexiones ponderadas. Cada neurona aplica una función de activación a la suma de sus entradas, facilitando la identificación de patrones complejos (Chen et al., 2021). En el ámbito médico, las redes neuronales son útiles para tareas como la clasificación de imágenes y el análisis de datos clínicos. También han surgido variantes como las redes neuronales convolucionales (CNN), efectivas en el procesamiento de imágenes médicas (Sarvamangala & Kulkarni, 2022), y las redes neuronales recurrentes (RNN), que son adecuadas para datos secuenciales, como registros de salud (Wang et al., 2019).

2.1.3 Aprendizaje Profundo (*Deep Learning*)

El aprendizaje profundo (DL) es una subcategoría del aprendizaje automático que utiliza redes neuronales con múltiples capas para procesar grandes volúmenes de datos. Estas redes pueden aprender características de alto nivel automáticamente, lo que las hace efectivas para tareas complejas como el reconocimiento de imágenes, el análisis de lenguaje natural y la interpretación de datos biomédicos (Mu & Zeng, 2019). El aprendizaje profundo ha permitido avances significativos en la precisión diagnóstica, superando en muchos casos a los métodos tradicionales. Recientemente, se han destacado arquitecturas como las redes generativas adversariales (GAN), útiles para generar imágenes médicas sintéticas (Hong et al., 2019), y las transformadoras (Transformers), aplicadas en el análisis de texto clínico (He et al., 2023).

2.1.4 Procesamiento de Lenguaje Natural (*Natural Language Processing - NLP*)

El procesamiento de lenguaje natural es una técnica clave que permite a las máquinas entender y procesar el lenguaje humano (Nadkarni et al., 2011). En el contexto médico, el NLP se utiliza para analizar registros de salud electrónicos, extraer información de notas clínicas y facilitar la interacción entre pacientes y sistemas de salud (Locke et al., 2021). Los desarrollos recientes en NLP han llevado a la creación de modelos de lenguaje de gran escala, como BERT (Koroteev, 2021) y GPT (Baktash & Dawodi, 2023), que mejoran la capacidad de las máquinas para entender el contexto y la intención en el lenguaje médico, permitiendo una mejor comprensión y uso de la información clínica.

2.1.5 Aprendizaje por Transferencia (*Transfer Learning*)

El aprendizaje por transferencia permite que un modelo previamente entrenado en una tarea se ajuste a una nueva tarea con un conjunto de datos más pequeño. Esto es especialmente útil en el diagnóstico

médico, donde a menudo hay una falta de grandes conjuntos de datos etiquetados para enfermedades raras o poco frecuentes, es decir, enfermedades con muy baja prevalencia, pero bien caracterizadas. Esta técnica optimiza el uso de modelos preentrenados, ahorrando tiempo y recursos, y mejorando la eficacia en el diagnóstico de condiciones menos comunes, facilitando la adaptación de modelos a nuevas áreas clínicas sin necesidad de un entrenamiento extenso desde cero (Kim et al., 2022).

2.1.6 Modelos Generativos

Los modelos generativos, como las GAN y los Autoencoders Variacionales (VAEs), se utilizan para crear datos sintéticos que pueden ayudar a mejorar el entrenamiento de modelos y abordar problemas de desequilibrio en los conjuntos de datos. Estas técnicas permiten generar ejemplos adicionales de clases minoritarias, lo que mejora la robustez y precisión de los modelos en el diagnóstico médico. La generación de datos sintéticos es particularmente útil en campos donde la obtención de datos reales es difícil o costosa, proporcionando un medio para enriquecer los conjuntos de datos y facilitar el entrenamiento efectivo (Yi et al., 2019).

2.1.7 Inteligencia Artificial Explicativa (Explainable AI - XAI)

La IA explicativa se centra en hacer que los modelos de IA sean más transparentes y comprensibles. En el contexto médico, es crucial que los profesionales de la salud puedan entender cómo un modelo llegó a una determinada conclusión o recomendación. La implementación de XAI no solo mejora la confianza de los médicos en las decisiones automatizadas, sino que también permite una mejor integración de la IA en el proceso de toma de decisiones clínicas, asegurando que las recomendaciones sean interpretables y basadas en evidencia (Chaddad et al., 2023).

2.2 Aplicaciones de la IA en el diagnóstico médico

El aprendizaje automático ha sido fundamental en la detección y diagnóstico de enfermedades, con múltiples investigaciones que respaldan su eficacia. Un ejemplo destacado es el sistema desarrollado por Google Health para la detección de cáncer de mama mediante redes neuronales convolucionales. En un estudio realizado por McKinney en 2020, se demostró que este sistema supera en precisión a los radiólogos humanos en la identificación de tumores en mamografías, lo que resultó en una reducción significativa de la tasa de falsos positivos (McKinney et al., 2020). Otro estudio, llevado a cabo por Gulshan et al. (2016), destacó el uso de modelos de aprendizaje automático para detectar retinopatía diabética a partir de imágenes de fondo de ojo, logrando una precisión comparable a la de especialistas en oftalmología y facilitando diagnósticos más rápidos y accesibles (Gulshan et al., 2016).

En el ámbito oncológico, el aprendizaje automático está siendo utilizado para personalizar tratamientos basados en datos genéticos. Por ejemplo, un sistema de aprendizaje automático puede aprender a reconocer estructuras particulares en mamografías que están asociadas con un mayor riesgo de cáncer de mama o realizar la clasificación de Gleason en cánceres de próstata, evaluando la agresividad del tumor mediante el análisis de las células cancerosas en las biopsias, determinando qué tan anormales son en comparación con las células sanas para orientar el tratamiento adecuado, o también puede clasificar los cánceres de piel según la apariencia visual de las lesiones (Nardini, 2020).

A su vez, el aprendizaje automático está transformando la oncología radioterápica al mejorar la automatización y la eficiencia en el tratamiento del cáncer, utilizando datos como imágenes en 3D y dosis de radiación. Su integración en los flujos de trabajo clínicos optimiza la consistencia de los tratamientos y facilita la gestión de datos, lo que se traduce en beneficios directos para los pacientes. Esta innovación requiere una colaboración estrecha entre expertos, incluidos los físicos, para asegurar su correcta implementación y funcionamiento (Field et al., 2021).

Además, en el contexto quirúrgico, los modelos de aprendizaje automático están demostrando ser útiles en la predicción de complicaciones postoperatorias. Un estudio mostró que un modelo puede anticipar la necesidad de transfusiones de sangre en pacientes sometidos a artroplastia total de rodilla (TKA), lo que mejora la planificación quirúrgica. Al permitir que los médicos anticipen el riesgo de transfusiones antes de la intervención, se optimiza la preparación quirúrgica y se incrementa la

seguridad del paciente (Jo et al., 2020).

Por otro lado, estas herramientas computacionales también están optimizando la programación de citas médicas, en algunas instituciones de salud se han empleado algoritmos de aprendizaje automático para predecir las ausencias en citas médicas, logrando una reducción del 10.3% en la tasa de inasistencias al implementar un sistema de recordatorios para pacientes en riesgo (Dunstan et al., 2023), mejorando la eficiencia en la atención médica.

Asimismo, investigaciones recientes han utilizado modelos de aprendizaje automático para detectar enfermedades respiratorias como la COVID-19 a partir de tomografías computarizadas. En un estudio de Wang del 2020, se demostró que estos modelos pueden identificar características típicas de la enfermedad en imágenes pulmonares con alta precisión, contribuyendo a diagnósticos más rápidos y efectivos (Wang et al., 2020).

De manera similar, en el ámbito de las enfermedades cardiovasculares, la IA se ha utilizado para analizar electrocardiogramas (ECG) y otros datos de salud, facilitando la identificación temprana de arritmias y otros problemas cardíacos (Al Kuwaiti et al., 2023). Las aplicaciones de aprendizaje profundo en imagenología cardiovascular incluyen el uso en ecocardiografía para la segmentación automática del corazón y la evaluación de estructuras ventriculares, mejorando la identificación de patologías como la hipertrofia y la amiloidosis. En resonancia magnética cardíaca (CMR) y tomografía computarizada cardíaca (CCT), el DL ha permitido la segmentación precisa de cavidades cardíacas y la identificación de tejido adiposo epicárdico, lo que mejora la predicción de eventos cardiovasculares. También se ha aplicado DL en la imagenología nuclear para determinar isquemia a partir de datos en mapas polares, aunque su eficacia depende del contexto de uso y de las características de los datos analizados (Wehbe et al., 2023).

Las aplicaciones de la inteligencia artificial en oftalmología, a través de métodos de DL, se emplean en imágenes de fondo de ojo, tomografía de coherencia óptica (OCT) y pruebas de campo visual para facilitar la detección de anomalías corneales y retinianas. Dispositivos equipados con algoritmos de IA permiten realizar cribados de afecciones como la ambliopía y la retinopatía diabética, mejorando la eficiencia y reduciendo el riesgo de diagnósticos erróneos. Además, modelos de aprendizaje automático identifican trastornos como el glaucoma y la degeneración macular asociada a la edad (AMD), alcanzando niveles de precisión comparables a los de especialistas entrenados. (Han, 2022). Otra área en la que la IA ha tenido un impacto notable es la medicina personalizada. Los algoritmos de IA pueden analizar el perfil genético de un paciente y correlacionarlo con datos de tratamientos anteriores, prediciendo así cómo responderá a ciertos medicamentos o terapias. Este enfoque permite a los médicos diseñar tratamientos más específicos y eficaces, lo que a su vez mejora los resultados clínicos y optimiza el uso de recursos médicos (Gifari, 2021). Un ejemplo de esto es el caso de la elección de medicamentos en terapias para las neoplasias, como el cáncer de mama y de pulmón (Rezayi et al., 2022).

Otras aplicaciones de la IA también se emplean como herramientas en la toma de decisiones clínicas y se enfocan principalmente en apoyar el proceso de razonamiento de los médicos, sin reemplazarlos. Estas herramientas, se utilizan en forma de apoyo o asesoría, influyendo en las decisiones clínicas sin interactuar directamente con los pacientes, ayudan a los profesionales de la salud a interpretar datos complejos y a tomar decisiones informadas basadas en evidencia, de manera que pueden alertar a los médicos sobre posibles diagnósticos erróneos, sugerir pruebas adicionales y recomendar tratamientos basados en las últimas guías y hallazgos de investigación (Smith y Fotheringham, 2020).

2.3 Consideraciones éticas y relevancia de los datos en IA

La implementación de sistemas de inteligencia artificial en medicina requiere no solo el desarrollo técnico de algoritmos precisos, sino también la consideración de principios éticos y la calidad de los datos utilizados. No obstante, actualmente no existe una directriz general que haya sido aprobada o adoptada de manera unificada, en otras palabras, cada organización, sector o gobierno mantiene una postura diferente respecto a la ética de la IA, lo que ha impedido alcanzar un consenso sobre los principios y valores que deberían regir su uso (Huang et al. 2022).

Esta falta de dirección cobra especial relevancia al considerar los desafíos inherentes a la IA en el

ámbito clínico, donde la calidad deficiente de los datos o su falta de representatividad pueden introducir o amplificar el sesgo algorítmico, derivando en predicciones inexactas que exacerban las desigualdades en la atención sanitaria. Asimismo, la opacidad característica de los modelos de aprendizaje profundo genera una "caja negra" que socava la confianza profesional y compromete la autonomía del paciente, al impedir la explicación y justificación de las decisiones diagnósticas. Por consiguiente, es fundamental establecer marcos robustos de seguridad y atribución de responsabilidad que definan con claridad las obligaciones de desarrolladores, instituciones y clínicos ante eventuales fallos, garantizando que el despliegue de la IA se alinee con los principios de beneficencia, no maleficencia y el respeto a la dignidad humana (Zhang y Zhang, 2023).

Retomando la necesidad de una postura unificada, la investigación empírica subraya la urgencia de establecer un modelo de "ética incrustada" que promueva la colaboración sostenida e integral entre éticistas, desarrolladores de IA, clínicos y pacientes a lo largo de todo el ciclo de vida tecnológico. Los estudios empíricos indican que las preocupaciones centrales del personal médico se enfocan en dos áreas clave: la necesidad de mantener su autonomía profesional al tomar decisiones clínicas y asegurar la justicia distributiva, es decir, que la tecnología sea equitativa y accesible para todos los pacientes. Un punto de preocupación que comparten todos los involucrados es el riesgo de que la IA reduzca la interacción humana y la comunicación de confianza en la atención sanitaria. A pesar de esto, la investigación actual tiene serias debilidades metodológicas, como el hecho de que no se incluye a los desarrolladores de IA como sujetos de estudio principales y existe una notable falta de acuerdos en cómo definir y medir los conceptos éticos. Por lo tanto, es esencial lograr una colaboración genuinamente interdisciplinaria para transformar los principios éticos teóricos en directrices prácticas y concretas que aseguren que la IA médica se implemente de manera justa y confiable, sin olvidar la necesidad de incluir la perspectiva de regiones y países de bajos ingresos en la investigación (Tang et al. 2023).

3. Resultados y discusión

Los resultados de este trabajo evidencian que las aplicaciones de la IA en el diagnóstico médico han demostrado un impacto sustancial en la detección temprana, el tratamiento personalizado y la optimización de la toma de decisiones clínicas. Sin embargo, más allá de los logros técnicos, los hallazgos reflejan desafíos persistentes relacionados con la generalización de los modelos, la interpretabilidad de los resultados y la integración efectiva en los entornos clínicos reales.

En primer lugar, se observó que las redes neuronales convolucionales son las técnicas más ampliamente utilizadas en el diagnóstico basado en imágenes médicas, observándose que estos modelos pueden alcanzar o incluso superar el rendimiento de especialistas humanos en tareas específicas, como la detección de cáncer de mama y la retinopatía diabética. No obstante, la reproducibilidad de estos resultados depende en gran medida de la calidad y diversidad de los datos de entrenamiento, provocando una pérdida en la precisión cuando se aplican en contextos clínicos distintos a los de su entrenamiento.

Comparativamente, los avances en aprendizaje profundo han impulsado mejoras notables en precisión diagnóstica, aunque con un costo en términos de interpretabilidad. Mientras que las evidencias demuestran beneficios concretos en la automatización de la oncología radioterápica, otras investigaciones subrayan que la "caja negra" de estos algoritmos limita su aceptación por parte del personal médico. En este sentido, las aproximaciones de IA explicativa comienzan a cobrar relevancia, al permitir que los médicos comprendan las razones detrás de las decisiones automatizadas, fortaleciendo la confianza y facilitando la colaboración entre humanos y sistemas inteligentes.

Por otro lado, los estudios revisados confirman que la IA está contribuyendo significativamente al avance de la medicina personalizada. Modelos que integran datos genómicos y clínicos permiten anticipar la respuesta de los pacientes a determinados fármacos, lo que abre la puerta a terapias más eficaces y adaptadas. Sin embargo, estas mismas aplicaciones plantean retos éticos vinculados al uso de información genética sensible y a la necesidad de garantizar la protección y confidencialidad de los datos personales.

En cuanto a la eficiencia operativa en salud, se identificaron ejemplos en los que la IA contribuye a la optimización de procesos administrativos y la gestión hospitalaria, como la predicción de ausencias en citas médicas. Si bien estos avances mejoran la logística institucional, la discusión científica coincide en que la mayor promesa de la IA radica en su integración clínica directa, donde el juicio humano sigue siendo esencial para validar y contextualizar las recomendaciones automatizadas.

De manera transversal, los resultados sugieren que la adopción efectiva de la IA en la medicina requiere no solo de avances tecnológicos, sino también de marcos regulatorios, protocolos éticos y estrategias educativas que promuevan la alfabetización digital del personal médico. Estas consideraciones son esenciales para evitar el sesgo algorítmico y asegurar que la IA contribuya a la equidad en el acceso y la calidad de la atención sanitaria.

Finalmente, a partir del análisis de los estudios revisados, se infiere que la inteligencia artificial desempeña un papel fundamental en la transición de la medicina hacia un modelo más predictivo, preventivo y personalizado. No obstante, para alcanzar su máximo impacto, es imprescindible abordar no solo los desafíos técnicos de interoperabilidad, transparencia y validación clínica, sino también los aspectos éticos y la calidad de los datos que sustentan los algoritmos. La ausencia de directrices unificadas sobre ética en IA y la variabilidad en la calidad y representatividad de los conjuntos de datos pueden introducir sesgos algorítmicos que comprometan la equidad en la atención médica y reduzcan la confianza en los sistemas automatizados. En este sentido, la implementación responsable de la IA requiere marcos normativos y colaboraciones interdisciplinarias que aseguren la trazabilidad de las decisiones, la protección de la privacidad del paciente y la equidad en el acceso a la tecnología. Solo mediante esta integración entre innovación técnica y principios éticos será posible consolidar un modelo de medicina digital verdaderamente confiable, inclusivo y centrado en el paciente.

4. Conclusiones

Actualmente, la IA se está integrando en entornos clínicos específicos, pero su adopción enfrenta desafíos relacionados con la resistencia de algunos profesionales, la preparación técnica y la adaptación de los procesos clínicos existentes. Este trabajo ha evidenciado que, aunque los algoritmos de IA muestran un alto potencial para mejorar la precisión diagnóstica, la eficiencia de los procesos y la personalización de tratamientos, su implementación requiere considerar aspectos éticos, la privacidad de los datos y la confianza en los sistemas automatizados.

En síntesis, la IA se consolida como una herramienta transformadora en la medicina predictiva y personalizada, evidenciando un potencial diagnóstico que iguala o supera al especialista humano. No obstante, su implementación efectiva se encuentra condicionada a la superación de barreras no técnicas. La contribución principal de este estudio reside en la identificación de la tensión irreductible entre el avance tecnológico y la necesidad de interpretabilidad clínica. Se concluye que el futuro de la IA en medicina depende intrínsecamente de la adopción de marcos éticos incrustados, la protección rigurosa de los datos y la inclusión de todas las partes interesadas, asegurando así que la innovación se traduzca en equidad y confianza asistencial.

Conflictos de interés

Los autores declaran que no existe conflicto de interés

Contribución de autores

A.R. conceptualización del estudio, desarrollo de la investigación y redacción del manuscrito. G.Q. desarrollo de la investigación y redacción del manuscrito. Todos los autores leyeron, revisaron y aprobaron la versión final del documento.

Referencias

Al Kuwaiti, A., Nazer, K., Al-Reedy, A., Al-Shehri, S., Al-Muhanna, A., Subbarayalu, A. V., ... &

- Al-Muhanna, F. A. (2023). A review of the role of artificial intelligence in healthcare. *Journal of Personalized Medicine*, 13(6), 951. <https://doi.org/10.3390/jpm13060951>.
- Bajwa, J., Munir, U., Nori, A., & Williams, B. (2021). Artificial intelligence in healthcare: Transforming the practice of medicine. *Future Healthcare Journal*, 8(2), e188-e194. <https://doi.org/10.7861/fhj.2021-0095>.
- Baktash, J. A., & Dawodi, M. (2023). GPT-4: A review on advancements and opportunities in natural language processing. *arXiv*. <https://doi.org/10.48550/arXiv.2305.03195>.
- Briganti, G., & Le Moine, O. (2020). Artificial intelligence in medicine: today and tomorrow. *Frontiers in medicine*, 7, 509744. <https://doi.org/10.3389/fmed.2020.00027>.
- Chaddad, A., Peng, J., Xu, J., & Bouridane, A. (2023). Survey of explainable AI techniques in healthcare. *Sensors*, 23(2), 634. <https://doi.org/10.3390/s23020634>.
- Chen, L., Li, S., Bai, Q., Yang, J., Jiang, S., & Miao, Y. (2021). Review of image classification algorithms based on convolutional neural networks. *Remote Sensing*, 13(22), 4712. <https://doi.org/10.3390/rs13224712>.
- Dunstan, J., Villena, F., Hoyos, J. P., Riquelme, V., Royer, M., Ramírez, H., & Peypouquet, J. (2023). Predicting no-show appointments in a pediatric hospital in Chile using machine learning. *Health Care Management Science*, 26(2), 313-329. <https://doi.org/10.1007/s10729-022-09626-z>.
- Field, M., Hardcastle, N., Jameson, M., Aherne, N., & Holloway, L. (2021). Machine learning applications in radiation oncology. *Physics and Imaging in Radiation oncology*, 19, 13-24. <https://doi.org/10.1016/j.phro.2021.05.007>.
- Gifari, M. W., Samodro, P., & Kurniawan, D. W. (2021). Artificial intelligence toward personalized medicine. *Pharmaceut. Sci. Res*, 8(2), 1.
- Gulshan, V., Peng, L., Coram, M., et al. (2016). Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA*, 316(22), 2402-2410. <https://doi.org/10.1001/jama.2016.17216>.
- Han, J. H. (2022). Artificial intelligence in eye disease: recent developments, applications, and surveys. *Diagnostics*, 12(8), 1927. <https://doi.org/10.3390/diagnostics12081927>.
- He, K., Gan, C., Li, Z., Rekik, I., Yin, Z., Ji, W., ... & Shen, D. (2023). Transformers in medical image analysis. *Intelligent Medicine*, 3(1), 59-78. <https://doi.org/10.1016/j.imed.2022.07.002>.
- Hong, Y., Hwang, U., Yoo, J., & Yoon, S. (2019). How generative adversarial networks and their variants work: An overview. *ACM Computing Surveys*, 52(1), 1-43. <https://doi.org/10.1145/3301282>.
- Huang, C., Zhang, Z., Mao, B., & Yao, X. (2022). An overview of artificial intelligence ethics. *IEEE Transactions on Artificial Intelligence*, 4(4), 799-819. <https://doi.org/10.1109/TAI.2022.3194503>.
- Jo, C., Ko, S., Shin, W. C., Han, H. S., Lee, M. C., Ko, T., & Ro, D. H. (2020). Transfusion after total knee arthroplasty can be predicted using the machine learning algorithm. *Knee Surgery, Sports Traumatology, Arthroscopy*, 28, 1757-1764. <https://doi.org/10.1007/s00167-019-05602-3>.
- Kaul, V., Enslin, S., & Gross, S. A. (2020). History of artificial intelligence in medicine. *Gastrointestinal Endoscopy*, 92(4), 807-812. <https://doi.org/10.1016/j.gie.2020.06.040>.
- Kim, H. E., Cosa-Linan, A., Santhanam, N., Jannesari, M., Maros, M. E., & Ganslandt, T. (2022). Transfer learning for medical image classification: A literature review. *BMC Medical Imaging*, 22(1), 69. <https://doi.org/10.1186/s12880-022-00793-7>.
- Koroteev, M. V. (2021). BERT: A review of applications in natural language processing and understanding. *arXiv*. <https://doi.org/10.48550/arXiv.2103.11943>.
- Locke, S., Bashall, A., Al-Adely, S., Moore, J., Wilson, A., & Kitchen, G. B. (2021). Natural language processing in medicine: A review. *Trends in Anaesthesia and Critical Care*, 38, 4-9. <https://doi.org/10.1016/j.tacc.2021.02.007>.
- Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research*, 9(1), 381-386. <https://doi.org/10.21275/ART20203995>.
- McKinney, S. M., Siennicki-Lantz, A., & Khoshgoftaar, T. M. (2020). International evaluation of an AI system for breast cancer screening. *Nature*, 577(7788), 89-94. <https://doi.org/10.1038/s41586-019-1799-6>.

- Mu, R., & Zeng, X. (2019). A review of deep learning research. *KSII Transactions on Internet and Information Systems*, 13(4), 1738–1764. <https://doi.org/10.3837/tiis.2019.04.001>.
- Muthukrishnan, N., Maleki, F., Ovens, K., Reinhold, C., Forghani, B., & Forghani, R. (2020). Brief history of artificial intelligence. *Neuroimaging Clinics of North America*, 30(4), 393-399.
- Nadkarni, P. M., Ohno-Machado, L., & Chapman, W. W. (2011). Natural language processing: an introduction. *Journal of the American Medical Informatics Association*, 18(5), 544-551. <https://doi.org/10.1136/amiajnl-2011-000464>.
- Nardini, C. (2020). Machine learning in oncology: a review. *Ecancermedicalscience*, 14. <https://doi.org/10.3332/ecancer.2020.1065>.
- Rezayi, S., R Niakan Kalhori, S., & Saeedi, S. (2022). Effectiveness of artificial intelligence for personalized medicine in neoplasms: a systematic review. *BioMed research international*, 2022(1), 7842566. <https://doi.org/10.1155/2022/7842566>.
- Rong, G., Mendez, A., Assi, E. B., Zhao, B., & Sawan, M. (2020). Artificial intelligence in healthcare: Review and prediction case studies. *Engineering*, 6(3), 291–301. <https://doi.org/10.1016/j.eng.2019.08.015>.
- Sarvamangala, D. R., & Kulkarni, R. V. (2022). Convolutional neural networks in medical image understanding: A survey. *Evolutionary Intelligence*, 15(1), 1–22. <https://doi.org/10.1007/s12065-020-00540-3>.
- Secinaro, S., Calandra, D., Secinaro, A., Muthurangu, V., & Biancone, P. (2021). The role of artificial intelligence in healthcare: A structured literature review. *BMC Medical Informatics and Decision Making*, 21(1), 1–23. <https://doi.org/10.1186/s12911-021-01488-9>
- Shinde, P. P., & Shah, S. (2018). A review of machine learning and deep learning applications. In *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)* (pp. 1-6). IEEE. <https://doi.org/10.1109/ICCUBEA.2018.8697857>.
- Smith, H., & Fotheringham, K. (2020). Artificial intelligence in clinical decision-making: rethinking liability. *Medical Law International*, 20(2), 131-154. <https://doi.org/10.1177/0968533220945766>.
- Tang, L., Li, J., & Fantus, S. (2023). Medical artificial intelligence ethics: A systematic review of empirical studies. *Digital health*, 9. <https://doi.org/10.1177/20552076231186064>.
- Wang, L., Lin, Z. Q., & Wong, A. (2020). Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images. *Scientific reports*, 10(1), 19549. <https://doi.org/10.1038/s41598-020-76550-z>.
- Wang, T., Tian, Y., & Qiu, R. G. (2019). Long short-term memory recurrent neural networks for multiple diseases risk prediction by leveraging longitudinal medical records. *IEEE Journal of Biomedical and Health Informatics*, 24(8), 2337–2346. <https://doi.org/10.1109/JBHI.2019.2962366>.
- Wehbe, R. M., Katsaggelos, A. K., Hammond, K. J., Hong, H., Ahmad, F. S., Ouyang, D., ... & Thomas, J. D. (2023). Deep learning for cardiovascular imaging: A review. *JAMA cardiology*, 8(11), 1089-1098. <https://doi.org/10.1001/jamacardio.2023.3142>.
- Yi, X., Walia, E., & Babyn, P. (2019). Generative adversarial network in medical imaging: A review. *Medical Image Analysis*, 58, 101552. <https://doi.org/10.1016/j.media.2019.101552>.
- Zhang, J., & Zhang, Z. M. (2023). Ethics and governance of trustworthy medical artificial intelligence. *BMC medical informatics and decision making*, 23(1), 7. <https://doi.org/10.1186/s12911-023-02103-9>.