

**Análisis de aplicaciones y metodologías de inteligencia artificial para el diagnóstico médico:
un enfoque en hipertensión arterial y diabetes en América Latina**

Luis Eduardo Gelvez Muñoz

Isaac Esteban Camargo Freile

Universidad Nacional Abierta y a Distancia UNAD
Escuela de Ciencias Básicas, Tecnología e Ingeniería ECBTI
Especialización en Ciencia de Datos y Analítica

2026

Resumen

La presente monografía realiza un análisis exhaustivo de la literatura científica sobre la aplicación de la Inteligencia Artificial (IA) y el Machine Learning (ML) en el diagnóstico y predicción de la hipertensión arterial y la diabetes. El trabajo se enmarca en la crisis de salud pública que estas enfermedades crónicas representan en las Américas y específicamente en Colombia, donde constituyen una de las principales causas de mortalidad y existe un subregistro diagnóstico que podría alcanzar el 50%. La investigación parte de una doble problemática fundamental; por un lado, la existencia de modelos de IA/ML que demuestran altas tasas de precisión predictiva (superiores al 90% en algunos casos) y, por otro, las enormes brechas en la detección y manejo de estas patologías en el sistema de salud real. La justificación de este estudio radica en la necesidad de resumir y organizar el conocimiento dividido para comprender el verdadero potencial y los obstáculos de estas tecnologías en contextos como el colombiano. Con el objetivo de analizar las metodologías existentes, esta monografía identifica los principales algoritmos predictivos, evalúa su desempeño documentado y esquematiza los desafíos técnicos, éticos y de infraestructura que limitan su implementación. Se centrará en las teorías del aprendizaje automático, las arquitecturas de Deep Learning y los conceptos de Salud Digital que sustentan las soluciones analizadas. De igual manera, el presente documento se basa en una revisión sistemática de la literatura. El propósito de este trabajo no es diseñar una aplicación, sino ofrecer una guía estructurada que permita a otros estudiantes o desarrolladores aplicar los conocimientos aquí recopilados en futuros proyectos reales. Esta monografía ofrece una base teórica y metodológica para orientar futuras investigaciones y el diseño de políticas de salud digital. Los hallazgos muestran que, aunque los modelos de IA presentan alto potencial en la

detección temprana de diabetes e hipertensión, su aplicación práctica en Colombia requiere superar limitaciones técnicas, éticas y de infraestructura.

Palabras clave: Inteligencia Artificial, Diabetes, Hipertensión, Prevención, Deep Learning, Redes Neuronales.

Abstract

This monograph conducts a comprehensive analysis of the scientific literature on the application of Artificial Intelligence (AI) and Machine Learning (ML) in the diagnosis and prediction of high blood pressure and diabetes. The work is framed within the public health crisis that these chronic diseases represent in the Americas and, specifically, in Colombia, where they are one of the leading causes of mortality and diagnostic underreporting could reach 50%. The research is based on a dual fundamental problem: on the one hand, the existence of AI/ML models that demonstrate high rates of predictive accuracy (over 90% in some cases) and, on the other, the enormous gaps in the detection and management of these pathologies in the current healthcare system. The justification for this study lies in the need to summarize and organize the existing knowledge to understand the true potential and obstacles of these technologies in contexts such as Colombia. With the aim of analyzing existing methodologies, this monograph identifies the main predictive algorithms, evaluates their documented performance, and outlines the technical, ethical, and infrastructural challenges that limit their implementation. It will focus on machine learning theories, deep learning architectures, and digital health concepts that underpin the analyzed solutions. Similarly, this document is based on a systematic literature review. The purpose of this work is not to design an application, but rather to offer a structured guide that allows other students or developers to apply the knowledge gathered here in future real-world projects. This monograph offers a theoretical and methodological basis to guide future research and the design of digital health policies. The findings show that, although AI models have great potential for the early detection of diabetes and hypertension, their practical application in Colombia requires overcoming technical, ethical, and infrastructural limitations.

Keywords: Artificial Intelligence, Diabetes, Hypertension, Prevention, Deep Learning, Neural Networks.

Tabla de Contenido

Introducción	10
Descripción del Problema	12
Planteamiento del Problema	12
Justificación	14
Objetivos	16
Objetivo General	16
Objetivos Específicos.....	16
Marco de Referencia	17
Marco Teórico.....	17
Marco Conceptual	18
Metodología	20
Método	20
Fase 1 Búsqueda y Selección de la Literatura	20
Fase 2 Extracción y Sistematización de Datos	21
Fase 3 Análisis, Síntesis y Visualización.....	21
Tipo de Estudio	25
Resultados.....	27
Aplicaciones Documentadas.....	27
Desafíos Tecnológicos Identificados	27
Algoritmos de Machine Learning Clásico	28
Modelos de Ensamble (Random Forest y Gradient Boosting)	29
Desempeño en Detección de Diabetes (DM2).....	45

Desempeño en Detección de Hipertensión (HTA) y Riesgo Cardiovascular	46
Desafíos Éticos.....	46
Desafíos Técnicos	47
Desafíos de Infraestructura y Operativos.....	49
Conclusiones	50
Referencias Bibliográficas	53

Lista de Tablas

Tabla 1	<i>Algoritmos de IA y ML para el Diagnóstico y Predicción de Diabetes Mellitus (DM)..</i>	37
Tabla 2	<i>Algoritmos de IA y ML para el Diagnóstico y Predicción de Hipertensión (HTA).....</i>	43
Tabla 3	<i>Definición de Datos Accesibles No Invasivos.....</i>	47

Lista de Figuras

Figura 1 <i>Frecuencia de Términos Clave en la Literatura</i>	22
Figura 2 <i>Red Conceptual de Articulación de los Principales Artículos</i>	23
Figura 3 <i>Funcionamiento Estructural del Algoritmo Support Vector Machine (SVM)</i>	29
Figura 4 <i>Funcionamiento Estructural del Algoritmo Random Forest (RF)</i>	30
Figura 5 <i>Funcionamiento Estructural del Algoritmo (GBM)</i>	30
Figura 6 <i>Funcionamiento Estructural del Algoritmo eXtreme Gradient Boosting (XGB)</i>	31
Figura 7 <i>Funcionamiento Estructural del Algoritmo Hoeffding Tree</i>	32
Figura 8 <i>Funcionamiento Estructural del Algoritmo using LOESS (GAMLOESS)</i>	33
Figura 9 <i>Funcionamiento Estructural del Algoritmo Redes Convolucionales (CNN)</i>	34
Figura 10 <i>Funcionamiento Estructural del Algoritmo Redes Neuronales Profundas (DNN)</i>	35
Figura 11 <i>Funcionamiento Estructural del Algoritmo Modelos Transformer</i>	36
Figura 12 <i>Rendimiento Comparativo de Algoritmos en Diabetes Mellitus (DM)</i>	42
Figura 13 <i>Análisis de Rendimiento en Hipertensión Arterial (HTA)</i>	45

Introducción

La transformación digital del sector salud ha dejado de ser una promesa futurista para convertirse en una necesidad operativa urgente, especialmente en regiones donde los sistemas sanitarios enfrentan presiones demográficas y financieras muy difíciles.

En América Latina, y particularmente en Colombia, la carga de enfermedades crónicas no transmisibles ha alcanzado proporciones epidémicas. La Diabetes Mellitus tipo 2 y la Hipertensión Arterial no son solo las principales causas de morbilidad y mortalidad, sino que representan un desafío importantemente alarmante.

Se estima que cerca de la mitad de los pacientes que padecen estas condiciones desconocen su estado, transitando hacia complicaciones irreversibles como la insuficiencia renal o accidentes cerebrovasculares sin recibir intervención oportuna.

En contraposición a esta realidad epidemiológica, la literatura científica reciente ha experimentado un crecimiento en el desarrollo de herramientas basadas en Inteligencia Artificial (IA) y Aprendizaje Automático (Machine Learning - ML).

Algoritmos avanzados, desde Árboles de Decisión hasta Redes Neuronales Convolucionales profundas, han demostrado en entornos controlados capacidades predictivas que a menudo superan la precisión humana, logrando exactitudes superiores al 90% en la clasificación de riesgos.

Sin embargo, existe una contradicción crítica: mientras los modelos matemáticos alcanzan la excelencia en los laboratorios de datos, su implementación efectiva en la atención primaria de los países en desarrollo sigue siendo insuficiente y fragmentada.

La presente monografía surge de la necesidad de investigar esa desconexión. No basta con saber que la tecnología existe; es importante entender cómo se comporta ante las

limitaciones en el mundo real. ¿Es viable implementar diagnósticos por imagenología retiniana basada en Deep Learning en zonas rurales donde la conectividad es precaria?

Este trabajo no pretende desarrollar un nuevo software, sino realizar una compilación y revisión crítica de la evidencia disponible entre 2019 y 2025, actuando como un puente entre la ingeniería de datos y la salud pública.

A través de una revisión sistemática estructurada, este documento analiza los algoritmos predictivos, evaluando no solo sus métricas de desempeño (sensibilidad, especificidad y área bajo la curva), sino también los desafíos éticos, técnicos y de infraestructura que condicionan su éxito.

Se aborda la problemática desde una perspectiva integral que incluye la calidad de los datos y el riesgo de sesgo algorítmico, factores determinantes para evitar que la tecnología vincule las inequidades sociales existentes.

El documento se estructura para guiar al lector desde la fundamentación del problema epidemiológico hacia la investigación técnica de las soluciones de IA. Se examinan desde los enfoques clásicos de aprendizaje supervisado hasta las arquitecturas de Deep Learning más recientes, finalizando con un análisis de los obstáculos para su despliegue.

Por último, esta investigación busca ofrecer una hoja de ruta teórica que permita a desarrolladores y tomadores de decisiones comprender qué herramientas son verdaderamente viables para implementar el diagnóstico médico en el contexto colombiano.

Descripción del Problema

Planteamiento del Problema

La hipertensión arterial y la diabetes mellitus tipo 2 se han consolidado como una epidemia y una de las principales causas de mortalidad y discapacidad en la región de las Américas.

En Colombia, la diabetes fue la octava causa de mortalidad general en 2022, mientras que la hipertensión es el principal factor de riesgo de morbilidad. La magnitud real del problema es aún más alarmante debido a los datos registrados se estima que cerca del 50% de las personas con diabetes en el país no están diagnosticadas, y los datos oficiales de hipertensión (prevalencia <6%) contrastan drásticamente con los estudios de las poblaciones que la sitúan en un 24%.

Esta brecha diagnóstica masiva impide un tratamiento oportuno y dispara la incidencia de complicaciones graves y costosas como la insuficiencia renal, los infartos de miocardio y las amputaciones.

En paralelo a esta crisis de salud pública, el campo de la Inteligencia Artificial (IA) y el Machine Learning (ML) ha producido avances exponenciales. La literatura científica documenta la existencia de modelos predictivos capaces de identificar el riesgo de diabetes e hipertensión con altos niveles de precisión.

Estudios específicos han demostrado que algoritmos como K-Nearest Neighbors (KNN) pueden alcanzar una precisión del 95.5% en la predicción de diabetes, y modelos de Deep Learning han logrado un 87% de exactitud en la predicción de hipertensión en poblaciones colombianas.

Estas tecnologías, que analizan desde datos clínicos estructurados hasta datos de wearables (dispositivo electrónico que se usa en el cuerpo humano) en tiempo real, representan un enorme potencial para pasar de un modelo de salud reactivo a uno proactivo y preventivo.

Aquí surge el problema central de esta monografía: existe una profunda desconexión entre el potencial tecnológico documentado y la crisis de salud pública que se vive realmente. A pesar de la existencia de algoritmos eficaces, su implementación a gran escala enfrenta barreras críticas como la falta de modelos validados para poblaciones latinoamericanas, el alto riesgo de sesgos en los algoritmos existentes, la desigualdad en el acceso a la infraestructura tecnológica y la falta de un marco ético claro.

El conocimiento sobre qué herramientas funcionan, en qué condiciones y cuáles son sus verdaderas limitaciones se encuentra fragmentado en cientos de estudios individuales.

Por lo tanto, el problema no es la ausencia de tecnología, sino la falta de una "hoja de ruta" clara, crítica y estructurada que mapee la investigación en IA/ML y lo contextualice a las necesidades y barreras específicas de Colombia y las Américas.

Sin esta visión consolidada, los esfuerzos para implementar soluciones de IA corren el riesgo de ser ineficientes, poco equitativos y desconectados de la realidad epidemiológica.

Justificación

La realización de esta monografía de compilación se justifica por su importante valor estratégico como puente entre la investigación tecnológica de vanguardia y las urgentes necesidades de la salud pública en Colombia y las Américas. Su pertinencia se fundamenta en tres pilares:

1. Impacto Académico y Científico: Si bien existen numerosos estudios individuales que validan algoritmos de IA/ML para el diagnóstico de diabetes e hipertensión, hay una notoria escasez de trabajos que consoliden, comparen y analicen críticamente este conocimiento de manera integral. Esta monografía abordará ese vacío al realizar una revisión sistemática que no solo identificará las tecnologías más prometedoras, sino que también analizará sus métricas de desempeño, los tipos de datos que utilizan y, crucialmente, sus limitaciones y sesgos documentados. El resultado será un análisis e investigación robusta y contextualizada, que servirá como una referencia fundamental y una "hoja de ruta" para futuras líneas de investigación aplicada en la región, evitando la duplicación de esfuerzos y señalando las áreas de mayor oportunidad.

2. Impacto Social y de Salud Pública: La hipertensión y la diabetes afectan desproporcionadamente a las poblaciones vulnerables y de zonas rurales, donde el acceso a diagnósticos es limitado. Al resumir el conocimiento sobre herramientas de bajo costo (como apps móviles) y modelos predictivos, esta investigación proporcionará a los directivos que toman decisiones y a las entidades de salud pública una base de evidencia clara sobre qué soluciones tecnológicas son más viables para hacer llegar el diagnóstico temprano a más personas vulnerables. Comprender las mejores prácticas y los desafíos de implementación es el primer

paso para diseñar políticas públicas efectivas que busquen reducir la alarmante brecha de subdiagnóstico y fomentar una cultura de prevención y equidad en la salud.

3. Impacto Práctico y Formativo: Para un profesional en Ciencia de Datos y Analítica, la capacidad de evaluar críticamente el estado de una tecnología es tan importante como la capacidad de implementarla. Esta monografía de compilación representa un ejercicio de investigación profundo que permite desarrollar una comprensión experta del dominio. El conocimiento consolidado sobre los algoritmos, la calidad de los datos requeridos y los marcos éticos es un activo invaluable para liderar futuros proyectos de desarrollo e implementación, asegurando que las soluciones no solo sean técnicamente sólidas, sino también responsables, éticas y verdaderamente adaptadas a las necesidades del contexto colombiano.

Objetivos

Objetivo General

Analizar las aplicaciones de Inteligencia Artificial (IA) empleadas en el diagnóstico y la predicción temprana de Hipertensión Arterial y Diabetes, con el fin de identificar los desafíos tecnológicos inmersos en el contexto de salud pública en América Latina.

Objetivos Específicos

Identificar los principales algoritmos de Inteligencia Artificial y Machine Learning, documentados en la literatura para el diagnóstico temprano de enfermedades crónicas.

Analizar el desempeño de los modelos de Inteligencia Artificial y Machine Learning en la detección temprana de Hipertensión Arterial y Diabetes DM2 en América Latina.

Evaluar los principales desafíos éticos, técnicos y de infraestructura que impactan en la integración efectiva de soluciones de Inteligencia Artificial y Machine Learning, en los sistemas de atención preventiva en salud pública.

Marco de Referencia

Marco Teórico

El marco teórico de esta monografía se estructura en torno a las teorías y modelos de aprendizaje automático que la literatura revisada identifica como fundamentales para la predicción y diagnóstico de la hipertensión y la diabetes.

1. Teorías del Aprendizaje Automático Clásico (Machine Learning): La mayoría de los modelos predictivos para enfermedades crónicas se basan en algoritmos de aprendizaje supervisado que analizan datos clínicos estructurados. Este trabajo se fundamentará en la teoría de:

Modelos Basados en Instancias: Como K-Nearest Neighbors (KNN), que clasifica a un paciente basándose en la similitud con casos conocidos. La literatura reporta su alta eficacia, alcanzando precisiones de hasta un 95.5% en la predicción de diabetes tipo 2.

Modelos de Ensamble: Como Random Forest (RF) y eXtreme Gradient Boosting (XGBoost). La teoría detrás de estos modelos se basa en combinar múltiples "predictores débiles" (árboles de decisión) para crear un modelo robusto y generalizable. Estudios específicos destacan al RF con precisiones del 92.16% y al XGBoost por su excelente capacidad de generalización (AUC-ROC de 0.6092).

2. Fundamentos de las Redes Neuronales Profundas (Deep Learning): Para problemas de mayor complejidad o con datos no estructurados, el Deep Learning es la teoría predominante. Se explorarán las bases de:

Redes Neuronales Densas (DNN): Se analizará su arquitectura multicapa, ideal para capturar relaciones no lineales en datos tabulares. Un ejemplo de su aplicación es el modelo

desarrollado para la predicción de hipertensión en Bolívar (Colombia), que alcanzó una precisión del 87%.

Redes Neuronales Convolucionales (CNN): Se abordará la teoría de su arquitectura especializada en el procesamiento de datos tipo grilla, como las imágenes. Su eficacia es evidente en la detección de retinopatía diabética, una complicación grave de la diabetes.

3. Enfoques de Modelado Alternativos: Más allá de los modelos predictivos tradicionales, la literatura también explora otros marcos teóricos para simular la progresión de enfermedades. Se revisará la teoría de los Mapas Cognitivos Difusos (Fuzzy Cognitive Maps - FCM), un enfoque basado en el conocimiento experto que modela relaciones causales entre signos y síntomas. Su valor no reside en la precisión numérica, sino en su capacidad cualitativa para validar diagnósticos y simular escenarios clínicos.

Marco Conceptual

Para garantizar la claridad y el rigor de esta monografía de compilación, se establece el siguiente marco conceptual que define el alcance de los términos clave.

Inteligencia Artificial (IA) y Aprendizaje Automático (ML): En este trabajo, se definen como el conjunto de metodologías y algoritmos que son el objeto de estudio de esta revisión. Se analizarán sus diversas aplicaciones documentadas en la literatura para la predicción y el diagnóstico médico.

Modelo Predictivo: Se conceptualiza como el aparato tecnológico central que se analiza en las investigaciones revisadas. Su función es tomar un conjunto de datos de entrada (variables) para estimar la probabilidad de un resultado de salud futuro (riesgo de hipertensión o diabetes).

Big Data en Salud: Se define como la principal fuente de datos que alimenta los modelos predictivos analizados. Abarca desde datos clínicos estructurados y socio ambientales hasta datos

no estructurados en tiempo real provenientes de wearables (dispositivo electrónico que se usa en el cuerpo humano) e imágenes médicas, cuya calidad y disponibilidad son un factor crítico de éxito.

Salud Digital (eHealth) y Salud Móvil (mHealth): Se conceptualizan como el principal canal de implementación y aplicación para los modelos predictivos estudiados. La idea de una aplicación móvil es el ejemplo más recurrente de cómo estas tecnologías buscan llegar al usuario final para el monitoreo y la prevención.

Hipertensión y Diabetes: Se definen como las enfermedades específicas sobre el que se acota esta revisión bibliográfica. Su relevancia se establece por su alta prevalencia y carga de enfermedad en Colombia y las Américas, lo que justifica la necesidad de abordar el conocimiento tecnológico disponible para su abordaje.

Metodología

Método

Se utilizó el método PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses), que permitió organizar y evaluar de forma sistemática los estudios sobre inteligencia artificial aplicada al diagnóstico temprano. Su aplicación garantizó la selección de evidencia confiable y facilitó la comparación de modelos predictivos en patologías como la diabetes y la hipertensión. Para asegurar el rigor y la sistematicidad de esta revisión documental, se adoptó un proceso estructurado en tres fases, inspirado en los lineamientos de las revisiones sistemáticas y en las fuentes bibliográficas analizadas. Este enfoque permitió que la selección y el análisis fueran transparentes, replicables y orientados al cumplimiento de los objetivos de la investigación.

Fase 1 Búsqueda y Selección de la Literatura

Esta fase inicial se centró en la identificación y recopilación del cuerpo de artículos científicos que constituyen la base de la monografía. Definición de las Fuentes: Se realizó una búsqueda exhaustiva en bases de datos académicas y repositorios de alto impacto, incluyendo Google Scholar, ScienceDirect, IEEE Xplore, PubMed, Nature, Redalyc y Dialnet. Estrategia de búsqueda: se definieron y combinaron términos clave utilizando operadores booleanos (and, or) para maximizar la pertinencia de los resultados. las principales cadenas de búsqueda incluyeron: ("inteligencia artificial" or "machine learning" or "deep learning") and ("diabetes" or "diabetes mellitus type 2") and ("predicción" or "diagnóstico"); ("artificial intelligence" or "machine learning") and ("hypertension") and ("prediction model" or "risk stratification"); ("salud digital" or "mHealth") and ("Colombia" or "Latino América"). Criterios de inclusión: Para filtrar los resultados, se aplicaron los siguientes criterios: Inclusión: Artículos publicados entre 2019 y

2025, investigaciones que presentaran resultados cuantitativos (precisión, exactitud, AUC), revisiones sistemáticas, estudios de caso de implementación y artículos enfocados en diabetes tipo 2 e hipertensión arterial. Se priorizaron estudios con relevancia para el contexto de Colombia, América Latina y Americas.

Fase 2 Extracción y Sistematización de Datos

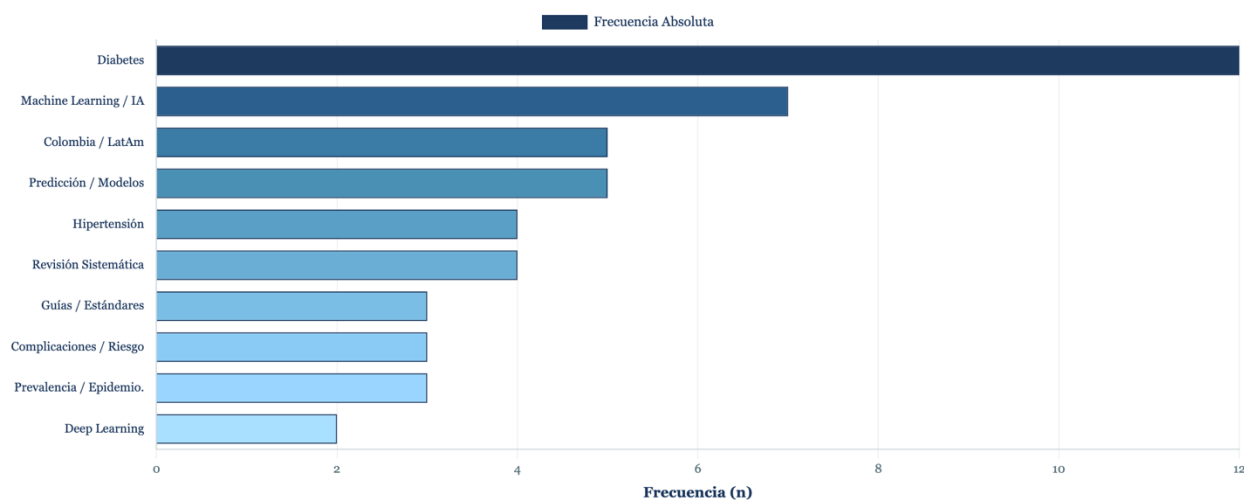
Una vez seleccionados los artículos finales, se procedió a extraer y organizar la información de manera sistemática utilizando una ficha de análisis documental para cada fuente. Esta ficha permitió estandarizar la recolección de los siguientes datos clave: Tipo de datos utilizados: Se documentó la naturaleza de los datos que alimentaron los modelos (clínicos, de laboratorio, de wearables, de imagenología, etc.). Técnicas de IA/ML empleadas: Se clasificaron los algoritmos específicos utilizados (p. ej., Random Forest, CNN, LSTM, XGBoost). Resultados y métricas de desempeño: Se registraron los resultados cuantitativos reportados (precisión del 95.5% para KNN, 87% para redes neuronales en HTA). Aplicaciones prácticas: Se identificaron menciones a sistemas o aplicaciones desarrolladas o conceptualizadas a partir de los modelos.

Fase 3 Análisis, Síntesis y Visualización

Esta es la fase final y más crítica del método, donde la información extraída se transforma en conocimiento estructurado. Análisis Temático: La información de las fichas se agrupó en categorías temáticas alineadas con los objetivos específicos: (a) Tipos de algoritmos y su desempeño. (b) Aplicaciones específicas para hipertensión y diabetes. (c) Desafíos éticos, técnicos y de infraestructura. Visualización de Datos: Para complementar el análisis narrativo y ofrecer una visión más clara del panorama de la investigación, se generaron representaciones gráficas como las que se presentan a continuación:

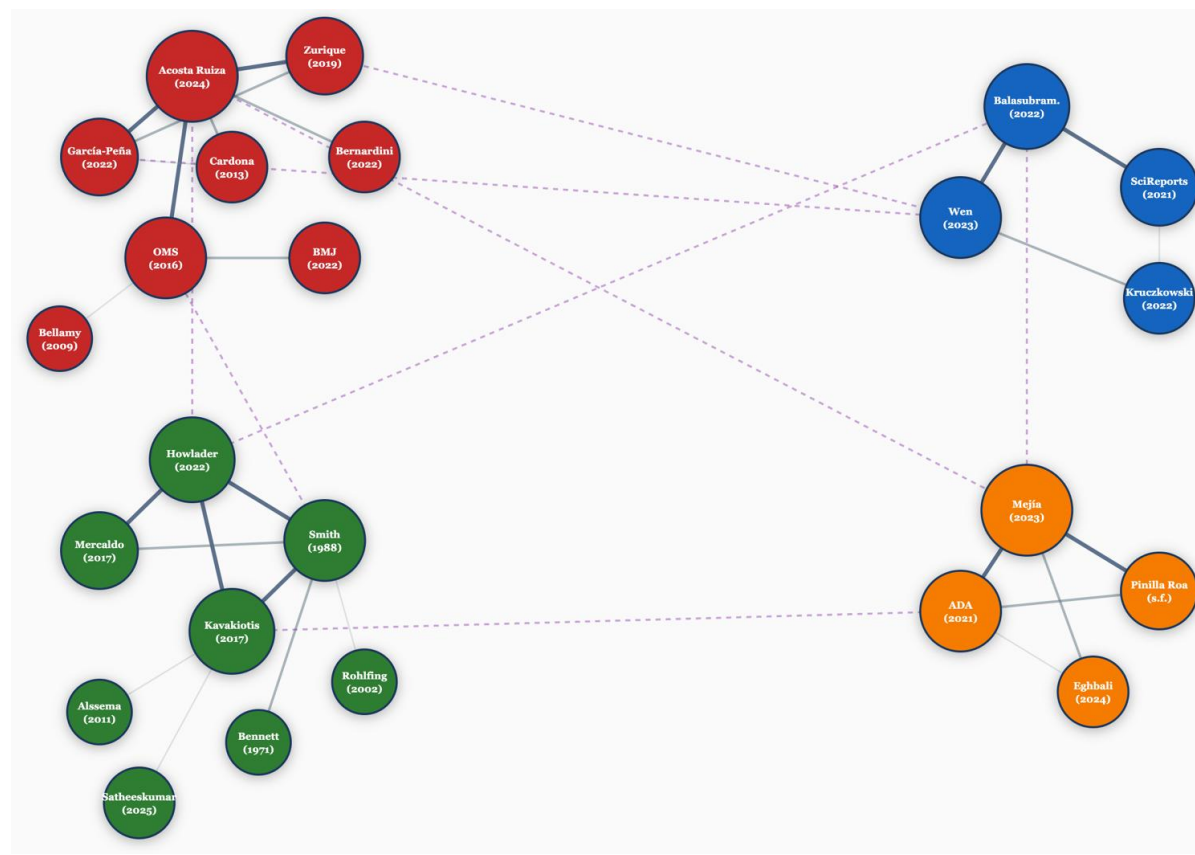
Figura 1

Frecuencia de Términos Clave en la Literatura



Nota. Esta visualización fue desarrollada por el autor con asistencia de Claude AI (Anthropic, 2025), una herramienta de inteligencia artificial conversacional utilizada para la generación del código HTML y diseño de la interfaz. (Gelvez, 2025).

El análisis cuantitativo revela una concentración temática significativa en diabetes (n=12), complementada por una presencia sustancial de estudios sobre aplicación de Machine Learning e Inteligencia Artificial (n=7). Se observa un enfoque geográfico definido en Colombia y Latinoamérica (n=5), así como una prevalencia de modelos predictivos (n=5) y segunda temática significativa hipertensión (n=4). La representación de Deep Learning (n=2) es notablemente inferior, sugiriendo una inclinación metodológica hacia técnicas de Machine Learning clásico en la literatura seleccionada. (Gelvez, 2025).

Figura 2*Red Conceptual de Articulación de los Principales Artículos*

Nota. Esta visualización fue desarrollada por el autor con asistencia de Claude AI (Anthropic, 2025), una herramienta de inteligencia artificial conversacional utilizada para la generación del código HTML y diseño de la interfaz. (Gelvez, 2025).

Descripción de Clústeres Temáticos:

Clúster Rojo: Epidemiología y Carga de la Enfermedad. Pilar Fundacional (8 fuentes) - Define la magnitud de la crisis de salud y establece el contexto específico de DM e HTA en Colombia y Latinoamérica. Artículos Clave: Acosta Ruiz (2024) - Revisión regional DM tipo 2; Zurique Sánchez (2019) - Meta-análisis HTA Colombia; García-Peña (2022) - Prevalencia HTA Colombia; Cardona-Arias (2013) - Factores de riesgo poblacional indígena; Bernardini (2022) -

Aspectos económicos DM; OMS (2016) - Informe mundial sobre diabetes; BMJ (2022) - Carga global DM tipo 2 en jóvenes; Bellamy (2009) - DM tipo 2 post-gestacional.

Clúster Verde: Machine Learning Clásico y Predicción. Pilar Tecnológico Central (8 fuentes) - Identifica y evalúa el rendimiento de algoritmos tradicionales de clasificación (SVM, RF, KNN) sobre datos clínicos tabulares. Artículos Clave: Howlader (2022) - Modelos ML para diagnóstico DM; Mercaldo (2017) - Clasificación y diagnóstico DM; Smith (1988) - Pima Indian Diabetes Dataset; Kavakiotis (2017) - Revisión Data Mining en diabetes; Alssema (2011) - Estrategias de detección temprana; Bennett (1971) - DM en población Pima; Rohlfing (2002) - Relación glucosa-HbA1c; Satheeskumar (2025) - ML en fase luna de miel DM1.

Clúster Azul: Deep Learning y Métodos No Invasivos. Pilar de Soluciones Avanzadas (4 fuentes) - Explora la aplicación de Redes Neuronales Profundas y métodos diagnósticos innovadores basados en imágenes. Artículos Clave: Balasubramaniyan (2022) - DL en imágenes panorámicas de lengua; Scientific Reports (2021) - CNN para diagnóstico por lengua; Wen (2023) - IA en imágenes retinianas para HTA/riñón; Kruczkowski (2022) - ML con método fotónico cervical.

Clúster Amarillo: Guías, Políticas y Contexto Socioeconómico. Pilar de Implementación (4 fuentes) - Conecta la tecnología con la salud pública, abordando viabilidad, accesibilidad y contexto normativo. Artículos Clave: Mejía (2023) - ML con datos socioeconómicos Colombia; American Diabetes Association (2021) - Guías prevención DM2; Pinilla Roa (s.f.) - Guía atención DM tipo 2 Colombia; Eghbali-Zarch (2024) - ML en gestión de insulina accesible.

Problema (Clúster rojo): Establece la crisis de DM/HTA en America Latina y Colombia mediante datos epidemiológicos, prevalencia y carga económica. Justifica la necesidad de soluciones tecnológicas.

Solución Técnica Clásica (Clúster verde): Revisa las herramientas históricas de ML aplicadas a datos clínicos tabulares, estableciendo el estado del arte del "qué funciona" con algoritmos tradicionales.

Solución Innovadora (Clúster azul): Explora el futuro del diagnóstico no invasivo mediante Deep Learning aplicado a imágenes (lengua, retina), representando el "qué es posible" con tecnologías emergentes.

Viabilidad y Contexto (Clúster amarillo): Analiza cómo los factores socioeconómicos, las guías clínicas y la accesibilidad dirigen la implementación práctica, abordando el "cómo aplicarlo" en el contexto colombiano.

Conclusión: Demuestra un diseño investigativo integral que no solo identifica soluciones tecnológicas, sino que las contextualiza dentro de la realidad epidemiológica, económica y normativa de las America Latina y Colombia, garantizando la relevancia y aplicabilidad de los hallazgos. Esta configuración valida el enfoque metodológico de revisión bibliográfica sistemática y compilación analítica. (Gelvez, 2025).

Tipo de Estudio

Este trabajo se enmarca en la modalidad de monografía de compilación y revisión bibliográfica. Se trata de una investigación de carácter cualitativo y documental, cuyo propósito es analizar, sintetizar y evaluar críticamente la exploración científica existente sobre un tema específico: la aplicación de la Inteligencia Artificial (IA) y el Machine Learning (ML) y el uso de BigData en el diagnóstico y predicción de la hipertensión y la diabetes. A diferencia de un proyecto aplicado, este estudio no contempla el desarrollo de un nuevo modelo algorítmico ni la construcción de un prototipo de software. Su valor no reside en la generación de datos primarios, sino en la consolidación del conocimiento disperso. El objetivo es construir un análisis

investigativo y comprensivo que mapee las metodologías más eficaces, identifique las tendencias tecnológicas, exponga los desafíos de implementación y señale los vacíos en las investigaciones, todo ello contextualizado a la realidad de salud pública de Colombia y la Región de las Américas.

Resultados

La literatura científica evidencia el uso de Inteligencia Artificial (IA) y Machine Learning (ML) para el diagnóstico y predicción de la Diabetes Mellitus (DM) y la Hipertensión Arterial (HTA). Sin embargo, su aplicación efectiva en América Latina, particularmente en Colombia, se ve limitada por una serie de desafíos tecnológicos y de infraestructura que crean una brecha entre el rendimiento teórico de los algoritmos y su implementación práctica en la salud pública. (Acosta R., 2024), (Mejía, 2023).

Aplicaciones Documentadas

Para Diabetes (DM2): La investigación se ha enfocado en modelos de aprendizaje supervisado. En datasets de referencia como el Pima Indian de Estados Unidos, algoritmos como el Generalized Boosted Regression Modeling (GBM) han alcanzado exactitudes de hasta el 90.91%. En Colombia, se han explorado enfoques adaptados a la realidad local, utilizando algoritmos como eXtreme Gradient Boosting (XGB) para predecir la DM2 a partir de datos socioeconómicos, aunque con una capacidad predictiva más baja (AUROC de 0.6092). (Vlahavas, I., 2017).

Para Hipertensión (HTA): La predicción se ha abordado de forma indirecta, principalmente a través del análisis de imágenes retinianas con Deep Learning (DL). Este método no invasivo permite predecir biomarcadores como la Presión Arterial Sistólica (SBP) y el riesgo de eventos cardiovasculares adversos. (Wen, J., 2023).

Desafíos Tecnológicos Identificados

Dependencia de Datos Clínicos: La capacidad predictiva de los modelos disminuye significativamente cuando no se tiene algunas variables fisiológicas costosas, como los análisis de sangre. (Wen, J., 2023).

Calidad de Datos y Sesgos: La heterogeneidad de los datos, la baja calidad de las imágenes (hasta un 16% puede ser inutilizable) y el riesgo de sesgos algorítmicos por etnia limitan la divulgación de los modelos. (Wen, 2023).

Infraestructura y Registro: La implementación de la IA se ve obstaculizada por la falta de tecnologías básicas en la atención primaria (como glucómetros) en países de bajos ingresos, así como por un subregistro sistemático de datos en fuentes oficiales como el SISPRO en Colombia. (OMS, 2016).

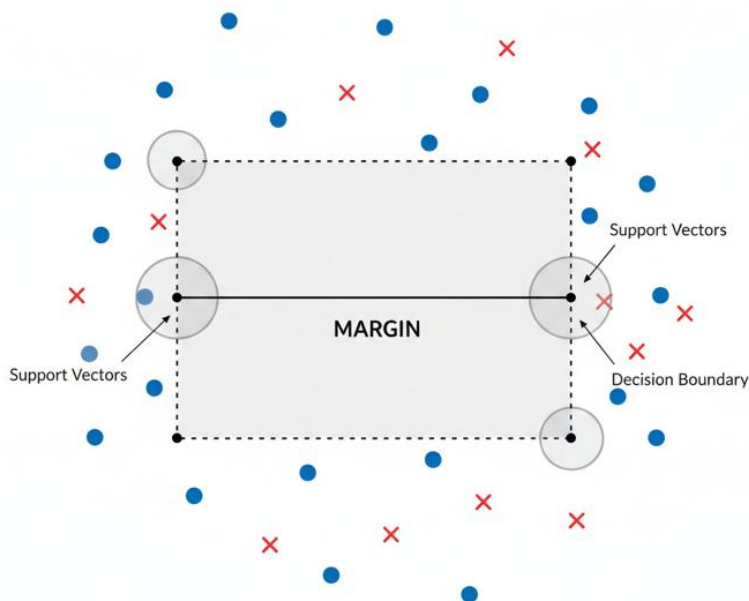
La revisión de la literatura permite identificar un conjunto diverso de algoritmos de IA y ML, con una preferencia del aprendizaje supervisado, que han sido aplicados al diagnóstico y predicción de la diabetes y en menor medida, de la hipertensión.

Algoritmos de Machine Learning Clásico

Support Vector Machine (SVM): Una SVM es un algoritmo de clasificación que busca el hiperplano que separa mejor las clases, maximizando el margen entre los datos de distinto tipo para lograr una separación robusta. Es uno de los algoritmos más referenciados y exitosos en datasets biológicos y clínicos para la diabetes, a menudo usado para clasificación y predicción de hipoglucemia. (Kavakiotis, I., 2017).

Figura 3

Funcionamiento Estructural del Algoritmo Support Vector Machine (SVM)



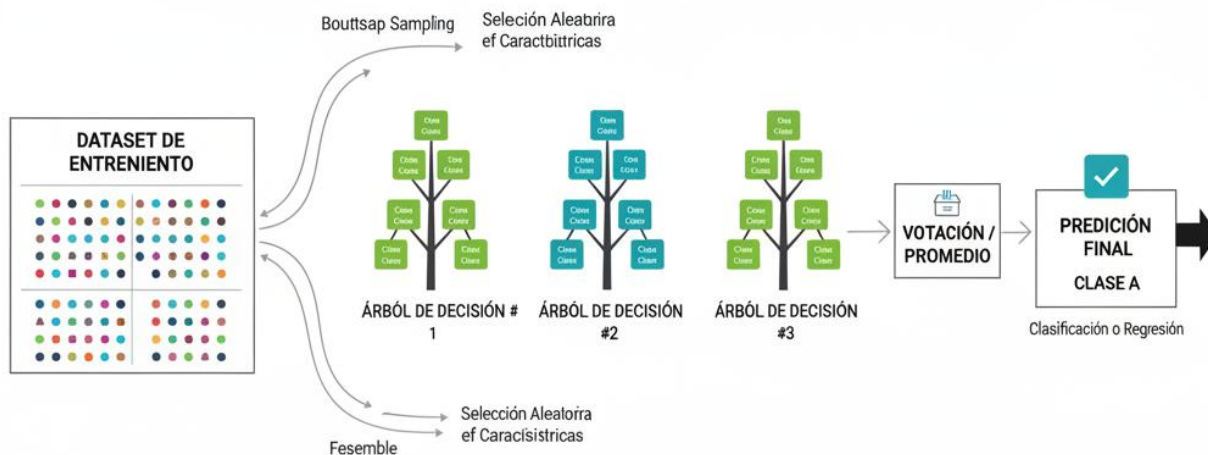
Nota. Esta visualización fue desarrollada por el autor con asistencia de AI STUDIO(Google, 2025), una herramienta de inteligencia artificial conversacional utilizada para la generación de imágenes. (Gelvez, 2025).

Modelos de Ensamble (Random Forest y Gradient Boosting)

Random Forest (RF): Es un algoritmo de aprendizaje automático de uso generalizado, que une el resultado de un árbol de decisión para llegar a un resultado clasificador robusto utilizado en la predicción de diabetes y sus complicaciones, como la neuropatía diabética periférica. (Kavakiotis, 2017).

Figura 4

Funcionamiento Estructural del Algoritmo Random Forest (RF)

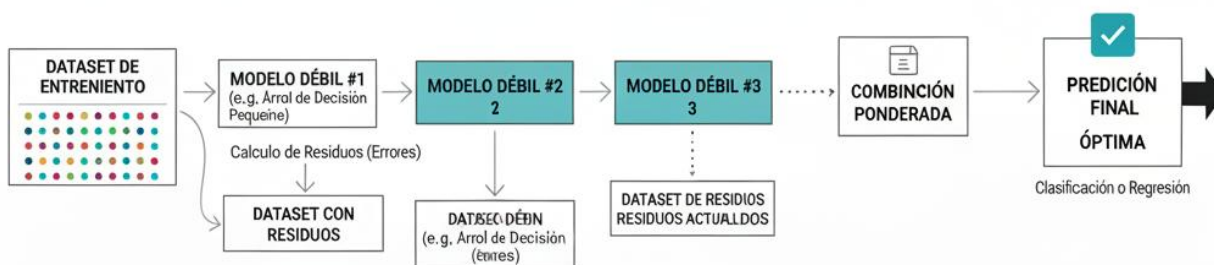


Nota. Esta visualización fue desarrollada por el autor con asistencia de AI STUDIO(Google, 2025), una herramienta de inteligencia artificial conversacional utilizada para la generación del imágenes. (Gelvez, 2025).

Generalized Boosted Regression Modeling (GBM): Es un algoritmo de aprendizaje que genera predicciones precisas al combinar varios árboles de decisión en un solo modelo. Ha sido el de mayor rendimiento en exactitud (90.91%) en el benchmark del dataset Pima para el diagnostico de la Diabetes Mellitus. (Kavakiotis, I., 2017).

Figura 5

Funcionamiento Estructural del Algoritmo (GBM)



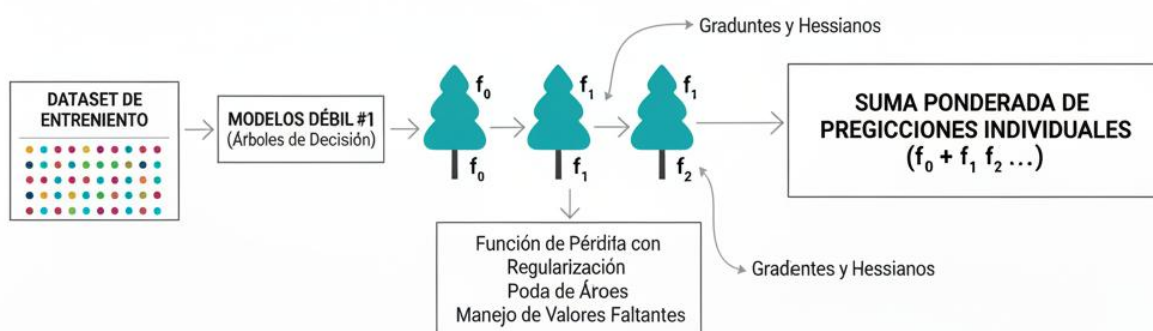
Nota. Esta visualización fue desarrollada por el autor con asistencia de AI STUDIO(Google,

2025), una herramienta de inteligencia artificial conversacional utilizada para la generación del imágenes. (Gelvez, 2025).

eXtreme Gradient Boosting (XGB): Es una biblioteca de machine learning distribuida y de código abierto que utiliza árboles de decisión potenciados por gradiente. Utilizado en Colombia para predecir Diabetes a partir de datos socioeconómicos, destacando por su capacidad de generalización. (Mejía, J., 2023).

Figura 6

Funcionamiento Estructural del Algoritmo eXtreme Gradient Boosting (XGB)



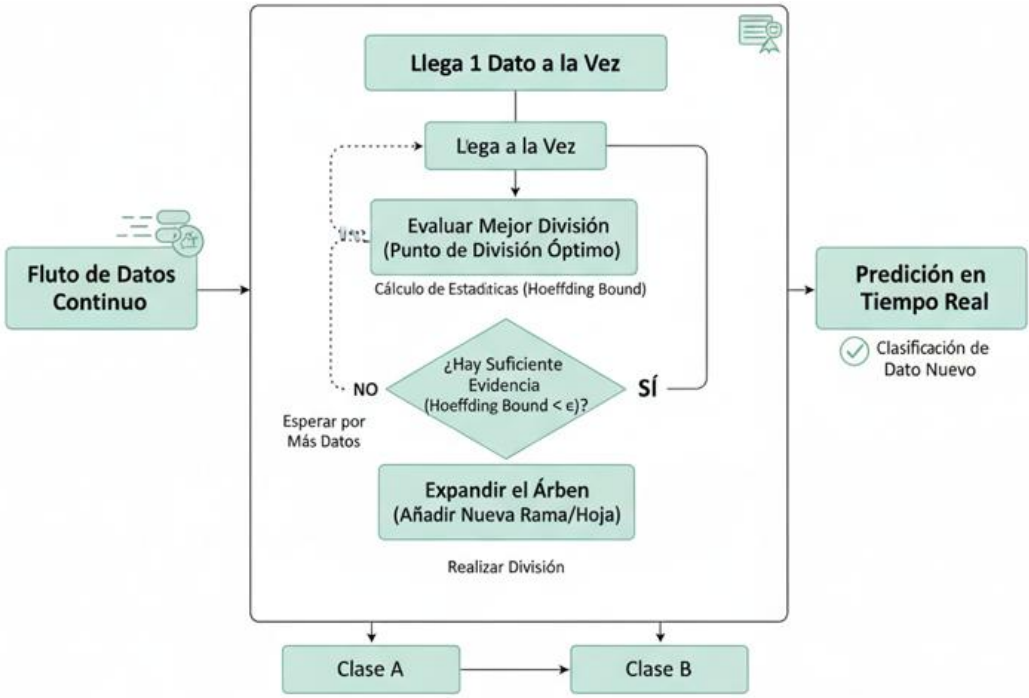
Nota. Esta visualización fue desarrollada por el autor con asistencia de AI STUDIO(Google, 2025), una herramienta de inteligencia artificial conversacional utilizada para la generación de las imágenes. (Gelvez, 2025).

Otros Clasificadores: Algoritmos como Hoeffding Tree y Generalized Additive Model using LOESS (GAMLOESS) también han sido evaluados, El Hoeffding Tree es un algoritmo de aprendizaje automático incremental diseñado para flujos de datos masivos, mientras que el Generalized Additive Model using LOESS (GAMLOESS) es un modelo estadístico flexible que utiliza el suavizado local (LOESS) para capturar relaciones no lineales entre variables,

destacando este último por su alta capacidad de distinción (AUROC de 95.26%) en el dataset Pima, para el diagnóstico de la Diabetes Mellitus.. (Mejía, J., 2023).

Figura 7

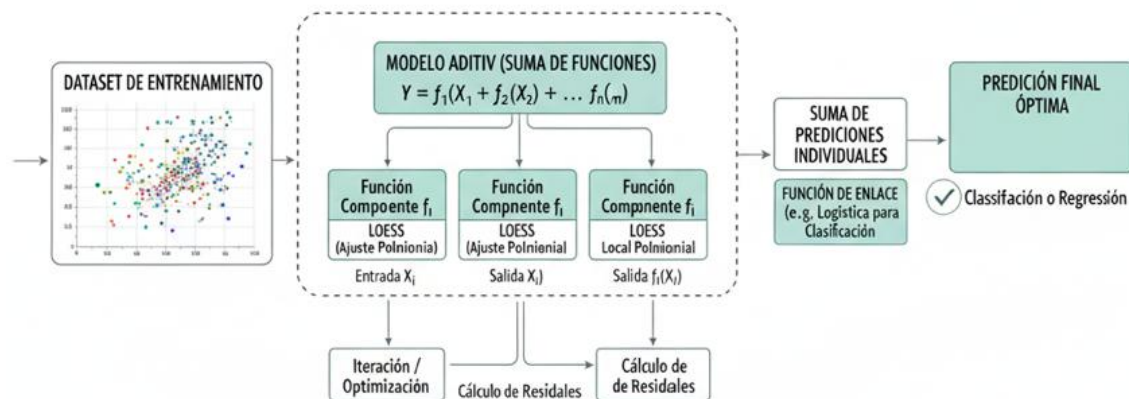
Funcionamiento Estructural del Algoritmo Hoeffding Tree



Nota. Esta visualización fue desarrollada por el autor con asistencia de AI STUDIO(Google, 2025), una herramienta de inteligencia artificial conversacional utilizada para la generación del imagenes. (Gelvez, 2025).

Figura 8

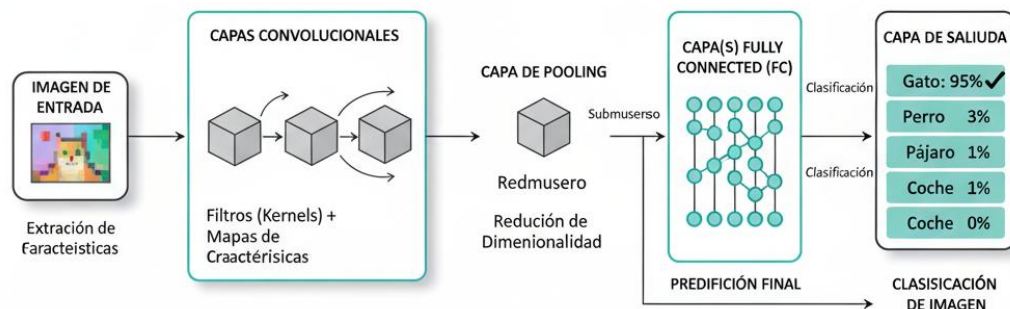
Funcionamiento Estructural del Algoritmo using LOESS (GAMLOESS)



Nota. Esta visualización fue desarrollada por el autor con asistencia de AI STUDIO(Google, 2025), una herramienta de inteligencia artificial conversacional utilizada para la generación del imágenes. (Gelvez, 2025).

Algoritmos de Deep Learning (DL):

Redes Neuronales Convolucionales (CNN): Son la técnica principal para el análisis de imágenes no estructuradas. Se utilizan para predecir factores de riesgo cardiovascular y HTA a partir de imágenes del fondo de ojo. (Wen, J., 2023).

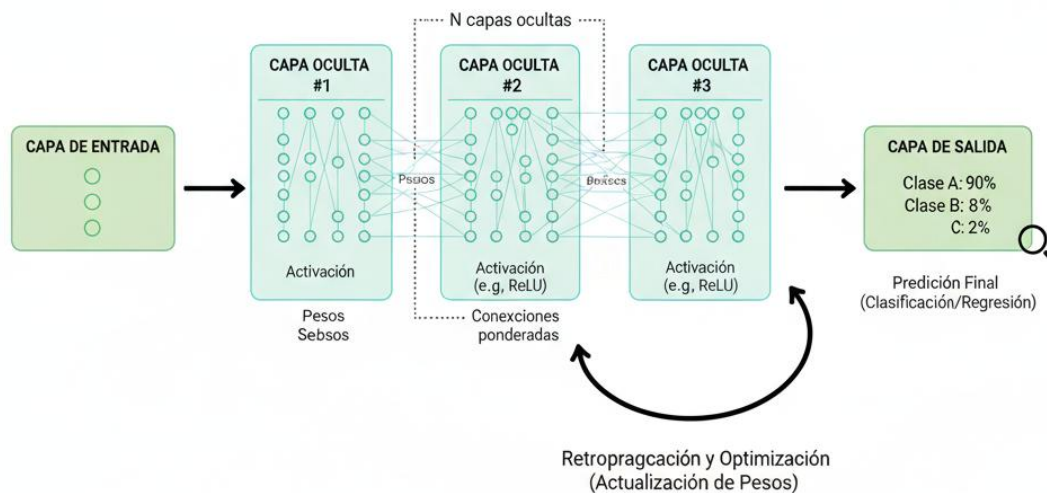
Figura 9*Funcionamiento Estructural del Algoritmo Redes Convolucionales (CNN)*

Nota. Esta visualización fue desarrollada por el autor con asistencia de AI STUDIO(Google, 2025), una herramienta de inteligencia artificial conversacional utilizada para la generación de imágenes. (Gelvez, 2025).

Redes Neuronales Profundas (DNN): Un modelo que utiliza arquitecturas de redes neuronales artificiales con múltiples capas ocultas para modelar y comprender datos complejos, que combina una arquitectura ResNet50 con una Red Neuronal de Base Radial (Deep RBFNN), ha mostrado una exactitud de 0.984 para el diagnóstico de Diabetes mediante el análisis de imágenes de la lengua, un método no invasivo (Wen, J., 2023).

Figura 10

Funcionamiento Estructural del Algoritmo Redes Neuronales Profundas (DNN)

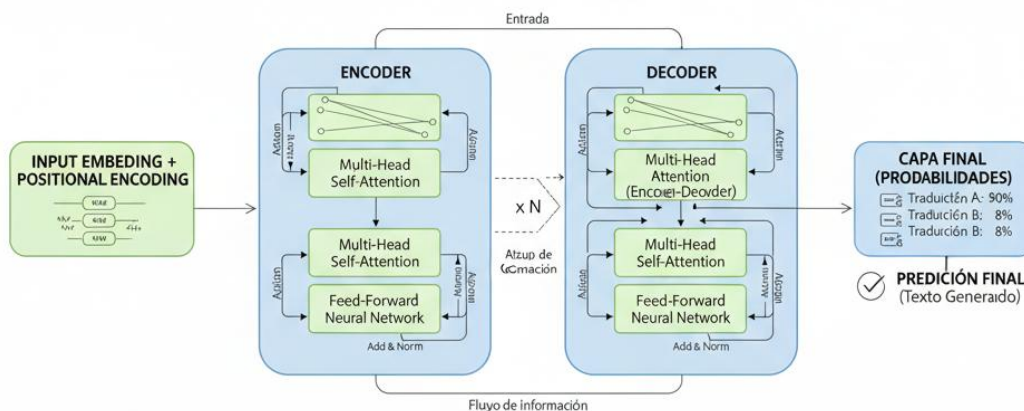


Nota. Esta visualización fue desarrollada por el autor con asistencia de AI STUDIO(Google, 2025), una herramienta de inteligencia artificial conversacional utilizada para la generación del imágenes. (Gelvez, 2025).

Modelos Transformer: Arquitectura de red neuronal que utiliza mecanismos de autoatención para procesar datos secuenciales, como el texto, se consideran modelos avanzados para analizar datos de monitorización continua de glucosa (CGM) y detectar fases específicas de la diabetes tipo 1. (Kavakiotis, I., 2017).

Figura 11

Funcionamiento Estructural del Algoritmo Modelos Transformer



Nota. Esta visualización fue desarrollada por el autor con asistencia de AI STUDIO(Google, 2025), una herramienta de inteligencia artificial conversacional utilizada para la generación del imágenes. (Gelvez, 2025).

El desempeño de los modelos varía grandemente según el tipo de datos utilizados, el algoritmo y el contexto poblacional. Los estudios analizados se centran principalmente en datasets de Estados Unidos y Colombia. Una amplia gama de algoritmos de ML se emplearon y evaluaron para la clasificación y predicción de la DM, siendo el Aprendizaje Supervisado el enfoque más común, la tabla 1 muestra la descripción de los más representativos y métricas de evaluación de su desempeño.

Tabla 1

Algoritmos de IA y ML para el Diagnóstico y Predicción de Diabetes Mellitus (DM)

Algoritmo	Descripción y Uso Clave	Exactitud (Accuracy)	Precisión (Precision)	Sensibilidad (Recall)	Especificidad (Specificity)	Otras Metricas (Other Metrics)
Support Vector Machine (SVM)	Algoritmo más exitoso y ampliamente utilizado en datasets biológicos y clínicos para DM. Se ha usado en combinación con K-means clustering, Morlet Wavelet (MWSVM), y para predicción de hipoglucemia (SVR). Kavakiotis, et al.,(2017).	Diagnóstico Imágenes de lengua (0.927)	No específica	Analisis de diagnósticos previos (0.945)	No específica	F1 Score 0.955
HoeffdingTree (A3)	Usado para la clasificación y diagnóstico de pacientes con DM. Mercado, F.(2017). Evaluado con el Pima Indian Diabetes Dataset (PIDD). Mercado, et	No específica	0.770 (4 características)	0.775 (4 características)	No específica	AUROC 0.824

	al.,(2017).		(completo)	(completo)	
	Utilizado en para detección de DM2.	90.91%			
	También en detección de fase "luna de miel" en DM1 pediátrica. Howlader, et al., (2022).	(PIDD) 89% (DM1)	No específica	No específica	85.19%
Generalized Boosted Regression (GBM)	Utilizado en análisis del PIDD. Mejor clasificado según prueba no paramétrica de Friedman. Howlader, et al., (2022).	No específica	No específica	No específica	Kappa Statistics Máxima 78.77%
GAMLOESS					No específica
					AUROC Máx95.26%
	Utilizado en el análisis del PIDD. Howlader, et al., (2022).	No específica	No específica	100%	Logloss Mín (Mediana) 45.58%
Sparse Distance					No específica AUROC

Weighted					Máx95.26%
Discrimination					Menor
(SDWD)					pérdida
					logarítmica
	Modelo avanzado para detección de fase	91%			(30,98%)
	"luna de miel" en DM1 pediátrica,		90%		
Transformer	analizando datos de monitorización		89%	92%	F1 Score 89%
Models	continua de glucosa (CGM).				
	Satheeskumar, R., (2025).				
	Clasificador robusto para predicción de				
	DM, neuropatía diabética periférica				
	(DPN) y fase "luna de miel" en DM1.	89% (DPN)			
Random	Kavakiotis, I. et al. (2017).	87% (DM1)	0.754		F1 Score 84%
Forest (RF)			(completo)	0.758	No específica
	Predicción de DM a partir de datos		0.743 (4	(completo)	

	socioeconómicos y ambientales.	60.55%	características)	0.747 (4	
	Mejía, J. A. et al. (2023).			características)	AUROC
			No específica		Máx60.9%
eXtreme	Metodología no invasiva basada en			48.44%	73.39%
Gradient	análisis de imágenes panorámicas de la				
Boosting	lengua (Medicina Tradicional China).	0.984			
(XGB)	Balasubramaniyan, S. et al. (2022).		0.989		F1 Score 99%
					Tasa de error
Deep RBFNN				0.991	0.943
con ResNet50					1.6%

Nota. La tabla documenta los modelos de Aprendizaje Automático (ML) más utilizados para la clasificación y predicción de la DM, centrándose principalmente en la Diabetes Mellitus Tipo 2 (DM2). Aproximadamente el 85% de los estudios revisados utilizan el enfoque de Aprendizaje Supervisado.

La estructura de la tabla se resume de la siguiente manera:

Algoritmo: Enumera los modelos específicos de ML probados en datasets clínicos, como Support Vector Machine (SVM), Generalized Boosted Regression Modeling (GBM) y Deep RBFNN.

Descripción y Uso Clave: Detalla la aplicación del algoritmo. Por ejemplo, el SVM es el algoritmo más exitoso y ampliamente utilizado para DM, mientras que Deep RBFNN se emplea en una metodología no invasiva basada en el análisis de imágenes de la lengua.

Exactitud (Accuracy): Muestra el rendimiento general de clasificación de los modelos. Los resultados destacados incluyen el GBM con el valor más alto (90.91%) en el Pima Indian Diabetes Dataset (PIDD), y el Deep RBFNN con 0.984. El SVM exhibe el mejor rendimiento general en exactitud o AUC en estudios comparativos.

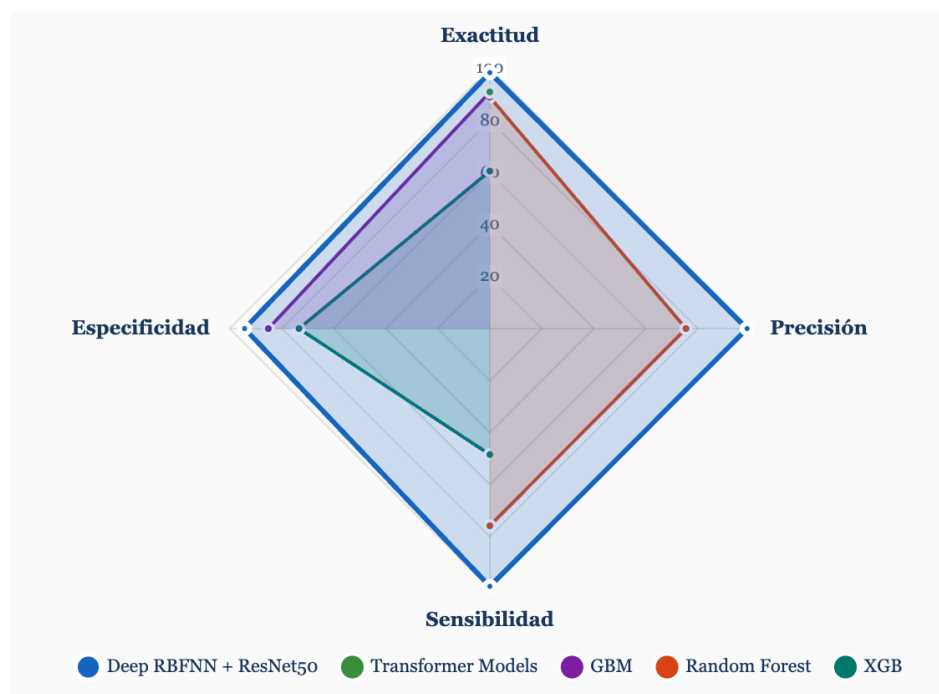
Precisión (Precision): Indica la proporción de resultados positivos correctos. El modelo Deep RBFNN registró una precisión elevada de 0.989.

Sensibilidad (Recall): Refleja la capacidad del modelo para identificar correctamente los casos positivos (verdaderos positivos). El algoritmo Sparse Distance Weighted Discrimination (SDWD) alcanzó la más alta (100%) en el estudio PIDD, y el Deep RBFNN obtuvo 0.991.

Especificidad (Specificity): Indica la capacidad del modelo para identificar correctamente los casos negativos (verdaderos negativos). El GBM registró la más alta (85.19%) en el estudio PIDD, y el Deep RBFNN alcanzó 0.943.

Figura 12

Rendimiento Comparativo de Algoritmos en Diabetes Mellitus (DM)



Nota. Esta visualización fue desarrollada por el autor con asistencia de Claude AI (Anthropic, 2025), una herramienta de inteligencia artificial conversacional utilizada para la generación del código HTML y diseño de la interfaz. (Gelvez, 2025). El análisis revela que Deep RBFNN con ResNet50 exhibe el mejor rendimiento integral con métricas superiores a 0.94 en todas las categorías. Los Transformer Models (91%) y GBM (90.91%) demuestran alta exactitud en aplicaciones específicas. SDWD alcanza sensibilidad perfecta (100%), aunque con limitaciones en otras métricas reportadas. El enfoque dominante es el Aprendizaje Supervisado (~85% de aplicaciones).

La detección y predicción de la HTA a través de técnicas de IA/ML se encuentra documentada principalmente mediante la siguiente tabla (Tabla 2) que detalla los algoritmos y las métricas medidas.

Tabla 2*Algoritmos de IA y ML para el Diagnóstico y Predicción de Hipertensión (HTA)*

Algoritmo	Descripción y Uso Clave	Exactitud (Accuracy)	Precisión (Precision)	Sensibilidad (Recall)	Otras Metricas (Other Metrics)
Deep Learning (DL) / CNN	Aplicado a imágenes retinianas. El ojo proporciona una ventana no invasiva para observar signos de enfermedades sistémicas, incluida la HTA. Wen, et al., (2023).	0.70 (eventos cardiovasculares)	No específica	No específica	La predicción de la Presión Arterial Diastólica (Diastolic BP) mediante CNN (MobileNet-V1) alcanzó un MAE de 6.89 y R^2 de 0.29.
Algoritmo DL (Poplin et al.)	Desarrollado para predecir factores de riesgo cardiovascular a partir de imágenes retinianas, incluyendo Presión Arterial Sistólica (SBP). Wen, et al., (2023).	MAE: 11.42 mmHg (SBP)	No específica	No específica	La predicción de eventos cardiovasculares adversos alcanzó un AUROC de 0.70
	Propuesto para predecir resultados de HTA a partir de datos médicos. Enfoque				

	en complicaciones de HTA o riesgo cardiovascular. Kruczkowski, et al., (2022).	0.82	No específica	No específica	La predicción de resultados relacionados con el estatus diabético (relacionado con el riesgo de CVD/HTA) mediante estos algoritmos alcanzó un AUROC entre 0.63–0.85.
Random Forest / Naïve Bayes / Decision Tree / Logistic Regression / Gradient Boosting	(insuficiencia renal con imágenes de fondo de ojo)				


Nota. La tabla describe que la detección y predicción de la Hipertensión Arterial (HTA) mediante técnicas de Inteligencia Artificial y Aprendizaje Automático (IA/ML) se documenta principalmente a través del análisis de imágenes retinianas. Los datos clave son:

Enfoque Principal: El ojo proporciona una ventana no invasiva para observar signos de enfermedades sistémicas, incluida la HTA.

Algoritmo Dominante: Se utiliza el Deep Learning (DL) / CNN aplicado a imágenes retinianas. Un algoritmo DL específico logró predecir eventos cardiovasculares adversos con una alta exactitud de 0.70. Métricas Específicas: Otro algoritmo DL se enfocó en predecir la Presión Arterial Sistólica (SBP) a partir de estas imágenes, alcanzando un Error Absoluto Medio (MAE) dentro de 11.42 mmHg. Otros Modelos: Algoritmos como Random Forest, Naïve Bayes, Árboles de Decisión y Regresión Logística también se han propuesto para predecir resultados de HTA a partir de datos médicos generales.

Figura 13

Análisis de Rendimiento en Hipertensión Arterial (HTA)



Nota. Esta visualización fue desarrollada por el autor con asistencia de Claude AI (Anthropic, 2025), una herramienta de inteligencia artificial conversacional utilizada para la generación del código HTML y diseño de la interfaz. (Gelvez, 2025). La literatura sobre algoritmos de IA/ML en HTA muestra que los enfoques predominantes utilizan análisis de imágenes retinianas mediante Deep Learning/CNN. Los algoritmos de Machine Learning clásico (Random Forest, Naïve Bayes) alcanzan exactitud de 0.82 en detección de complicaciones. El MAE de 11.42 mmHg en predicción de presión arterial sistólica sugiere un margen de mejora significativo. La investigación se centra principalmente en predicción de riesgo cardiovascular y complicaciones más que en diagnóstico directo de HTA.

Desempeño en Detección de Diabetes (DM2)

Con Datos Clínicos (Dataset Pima, Estados Unidos) que es un conjunto de datos muy utilizado en investigaciones de aprendizaje automático para la clasificación y diagnóstico de la Diabetes Mellitus Tipo 2 (DM2). (Howlader, K. 2022), los modelos alcanzan un rendimiento muy alto. El algoritmo GBM logró la más alta exactitud (90.91%) y especificidad (85.19%), mientras que el SDWD alcanzó una sensibilidad perfecta del 100%. El modelo GAMLOESS

mostró la mejor capacidad de discriminación general con un AUROC del 95.26%. (Kavakiotis, I., 2017).

Con Datos Socioeconómicos (Colombia): El desempeño es considerablemente más bajo, lo que refleja la dificultad de predecir sin variables clínicas. El modelo XGBoost, incluso con datos balanceados, alcanzó una exactitud del 60.55% y un AUROC de solo 0.6092, con una sensibilidad del 73.39%. Sin balancear los datos, la sensibilidad de los modelos era muy baja (entre 1.43% y 17.11%), lo que los hace inservibles para la detección. (Kavakiotis, I., 2017)

Desempeño en Detección de Hipertensión (HTA) y Riesgo Cardiovascular

Un modelo de Deep Learning (DL) logró predecir la Presión Arterial Sistólica (SBP) con un Error Absoluto Medio (MAE) de 11.42 mmHg, lo que indica la desviación promedio de la predicción respecto al valor real. Para predecir eventos cardiovasculares adversos (relacionados con la HTA), el mismo enfoque alcanzó un AUC de 0.70. El desempeño en la detección de HTA, que a menudo utiliza modelos basados en Imágenes Retinianas (Deep Learning), se mide de manera diferente a la diabetes. Esto se debe a que la meta no es siempre una clasificación binaria (sí/no), sino la predicción de valores continuos (como el SBP) o riesgos generales (como el AUC), lo que representa una capacidad de discriminación aceptable pero aún no excelente para el diagnóstico primario (Wen, J., 2023).

La integración de la IA en la salud pública de América Latina tiene tres desafíos relacionados que van más allá del simple rendimiento algorítmico.

Desafíos Éticos

Falta de Transparencia (Caja Negra): La dificultad para conocer cómo los modelos de IA llegan a un diagnóstico genera desconfianza y representa un riesgo ético si algoritmos

defectuosos causan daño a los pacientes. Esto ha llevado a una preferencia por modelos más simples pero entendibles como los Árboles de Decisión. (Kavakiotis, I., 2017).

Sesgo Algorítmico: Existe un riesgo considerable de que los modelos hagan que permanezcan desigualdades en la salud, ya que su rendimiento puede estar sesgado por el grupo especial de los datos de entrenamiento. (Mejía, J., 2023).

Privacidad de Datos: El uso de datos biométricos, como las imágenes de fondo de ojo, plantea un riesgo de identificación de individuos, ya que pueden actuar como una "huella dactilar" biológica. (Wen, J., 2023).

Desafíos Técnicos

Calidad y Disponibilidad de Datos: La generalidad de los modelos es dudosa debido a la diversidad de los datos. Una proporción grande de imágenes puede no tener la calidad suficiente (hasta un 16%) , y la diferencia de clases en los datasets puede llevar a un sobre entrenamiento y a una baja sensibilidad para detectar la enfermedad. (Kavakiotis, I., 2017), (Mejía, J., 2023).

Dependencia de Variables Clínicas: Los modelos más precisos dependen de datos orgánicos costosos inaccesibles invasivos (análisis de sangre o biopsias), mientras que los modelos basados en datos socioeconómicos, más accesibles no invasivos, tienen un poder predictivo limitado. (Mejía, J., 2023).

Tabla 3

Definición de Datos Accesibles No Invasivos

Criterio	Descripción	Datos Accesibles	Inaccesibles/Invasivos
Accesible	Información que se puede recopilar en entornos de bajos recursos (zonas rurales, atención	Información Socioeconómica (estrato, nivel educativo), Datos	Variables clínicas complejas que requieren análisis de

	primaria básica) sin equipos sofisticados o personal altamente especializado.	Ambientales, Hábitos de Vida, Mediciones Antropométricas (IMC, peso, talla), Imágenes Sencillas (como las de la lengua, si son capturables con un smartphone).	laboratorio (glucosa plasmática, perfil lipídico o imágenes de fondo de ojo con equipos especializados).
No Invasivo	La obtención de los datos no requiere procedimientos médicos (punción, extracción de sangre) que generen costo o incomodidad al paciente.	Cuestionarios, mediciones físicas simples y escaneo de imágenes externas.	Análisis de sangre, biopsias.

Nota. La tabla describe que priorizar modelos predictivos, depende de datos fácilmente recolectables con variables socioeconómicas (aunque menos precisos), el objetivo es cambiar el enfoque de máxima precisión diagnóstica (ideal en los laboratorios) a máxima viabilidad de cribado y priorización (necesaria en las zonas rurales o de poco acceso).

Falta de Especificación: La mayoría de los algoritmos son unimodales y no pueden diferenciar entre enfermedades con síntomas similares, lo que resalta la necesidad de migrar a modelos multimodales que integren diversas fuentes de datos. (Wen, J., 2023).

Desafíos de Infraestructura y Operativos

Brecha Tecnológica Básica: La implementación de IA avanzada no se alinea con la realidad de que muchos centros de atención primaria en países de bajos ingresos, carecen de tecnologías básicas como balanzas sensibles o glucómetros. (OMS., 2016).

Infraestructura Digital: La mala conectividad a internet puede retrasar el procesamiento de datos, y la falta de capacitación del personal puede resultar en la captura de datos de baja calidad. (Wen, J., 2023).

Subregistro de Datos: Sistemas de registro como el SISPRO en Colombia tienen limitaciones técnicas (solo almacenan el diagnóstico principal), lo que lleva a un subregistro de enfermedades crónicas como la HTA y dificulta la creación de datasets representativos. (Wen, J., 2023).

Conclusiones

La integración de la Inteligencia Artificial (IA) y el Aprendizaje Automático (ML) representa un avance importante en la lucha contra enfermedades crónicas como la Diabetes Mellitus (DM) y la Hipertensión Arterial (HTA). La evidencia demuestra que los algoritmos de aprendizaje supervisado, que son el enfoque dominante (85% de los estudios), han alcanzado métricas de rendimiento muy altas, superando las capacidades humanas de detección temprana en ciertos escenarios. Por ejemplo, modelos complejos como Deep RBFNN con ResNet50 han logrado una exactitud del 0.984 en el diagnóstico de diabetes mediante análisis de imágenes de la lengua, y el Generalized Boosted Regression Modeling (GBM) ha alcanzado una exactitud máxima del 90.91% en la clasificación de DM2 en el dataset de Pima. Además, la IA ha abierto nuevas vías no invasivas, como el uso de Deep Learning para predecir la Presión Arterial Sistólica (SBP) y el riesgo de eventos cardiovasculares adversos (AUC de 0.70) a partir de imágenes retinianas, lo que valida su utilidad para el cribado de riesgos sistémicos.

La Diabetes Mellitus representa una carga económica importante, impulsada por los altos costos de manejar sus complicaciones crónicas. Por ello, el principal beneficio de la Inteligencia Artificial radica en su potencial para ofrecer una atención genuinamente preventiva y sostenible. Se recomienda la implementación estratégica de modelos predictivos de bajo costo que utilicen datos accesibles y no invasivos, ya que el diagnóstico temprano no solo evita la progresión de la enfermedad, sino que genera un ahorro considerable al sistema de salud, siendo ideal para zonas rurales o de difícil acceso. Aunque los modelos más precisos dependen de variables clínicas y fisiológicas puntuales (como análisis de sangre), los estudios que utilizan solo información socioeconómica y ambiental, como el eXtreme Gradient Boosting (XGB) en el contexto Colombiano, son vitales, ya que ofrecen una herramienta clave para identificar y priorizar a las

poblaciones de alto riesgo en zonas rurales o en sistemas de salud con recursos limitados, permitiendo que las intervenciones de prevención se dirijan de forma inteligente, aunque el rendimiento de estos modelos pueda ser limitado (AUROC de 0.6092) en la práctica real.

Sin embargo, para que los beneficios de la IA se traduzcan en una mejora real de la salud pública, deben abordarse los riesgos éticos y de implementación. Existe una preocupación significativa por el sesgo algorítmico, ya que el rendimiento de los modelos puede estar sesgado por la distribución desproporcionada de grupos étnicos en los datasets, provocando potencialmente las desigualdades en la salud. A pesar de la precisión teórica de los modelos complejos, su hermetismo (la "caja negra") es un obstáculo fundamental para su integración en un sistema donde la confianza, la responsabilidad y la seguridad del paciente son pilares innegociables. Por esta razón, la literatura revisada a menudo favorece modelos más simples y "explicables" (como los Árboles de Decisión) sobre las arquitecturas de Deep Learning en el entorno clínico. Es imperativo desarrollar algoritmos que no solo sean precisos, sino también interpretables, y exigir validaciones sistemáticas y extensas en diversas poblaciones. Modelos que producen resultados de fácil lectura, como los Árboles de Decisión, a menudo son preferidos por su claridad.

La migración hacia modelos de Aprendizaje Multimodal es igualmente necesaria, ya que fusionar el análisis de imágenes con registros de salud electrónicos y datos de laboratorio permitirá una mayor especificidad diagnóstica y ayudará a diferenciar enfermedades con signos patológicos similares.

Finalmente, la brecha entre el rendimiento algorítmico teórico y la utilidad práctica se debe a desafíos críticos de infraestructura. En muchos países de ingresos bajos, la atención primaria carece de tecnologías básicas como glucómetros y balanzas. Asimismo, el subregistro

sistemático de datos en fuentes oficiales y la baja calidad de los datos de entrada (por ejemplo, hasta un 16% de las imágenes retinianas pueden ser inutilizables) obstaculizan el entrenamiento de modelos robustos y la vigilancia epidemiológica eficaz. Se recomienda que la estrategia de adopción de la IA esté intrínsecamente ligada a una inversión en la infraestructura digital básica y a la capacitación rigurosa del personal médico. Solo fortaleciendo la capacidad nacional para recopilar, analizar y utilizar datos representativos, y asegurando la disponibilidad de tecnología esencial, se podrá garantizar que las capacidades predictivas superiores de la IA y el ML se conviertan en un estándar de atención equitativo y confiable para el pronóstico de enfermedades crónicas.

Referencias Bibliográficas

- Acosta Ruiza, L. X., Angarita Merchán, M., & Orjuela Vargas, L. (2024). Diabetes mellitus tipo 2: Latinoamérica y Colombia, análisis del último quinquenio. *Revista Med*, 31(2), 35–46. <https://doi.org/10.18359/rmed.6067>
- American Diabetes Association. (2021). 3. Prevention or delay of type 2 diabetes: Standards of Medical Care in Diabetes—2021. *Diabetes Care*, 44(Suppl. 1), S34–S39. http://diabetesjournals.org/care/article-pdf/44/Supplement_1/S34/550809/dc21s003.pdf
- Alssema, M., Vistisen, D., Heymans, M. W., Nijpels, G., Glümer, C., Zimmet, P. Z., Shaw, J. E., Eliasson, M., Stehouwer, C. D. A., Tabák, A. G., y otros. (2011). The Evaluation of Screening and Early Detection Strategies for Type 2 Diabetes and Impaired Glucose Tolerance (DETECT-2) update of the Finnish diabetes risk score for prediction of incident type 2 diabetes. <https://doi.org/10.1007/s00125-010-1990-7>
- Balasubramaniyan, S., Jeyakumar, V., & Subramaniam Nachimuthu, D. (2022). Panoramic tongue imaging and deep convolutional machine learning model for diabetes diagnosis in humans. *Scientific Reports*, 12, Article 186. <https://www.nature.com/articles/s41598-021-03879-4>
- Bellamy, L., Casas, J-P., Hingorani, A. D., & Williams, D. (2009). Type 2 diabetes mellitus after gestational diabetes: a systematic review and meta-analysis. *The Lancet* 373, 9677, 1773–1779. [https://doi.org/10.1016/s0140-6736\(09\)60731-5](https://doi.org/10.1016/s0140-6736(09)60731-5)
- Bennett, P. H., Burch, T. A., & Miller, M. (1971). Diabetes mellitus in American (Pima) indians. *The Lancet* 298, 7716, 125–128. [https://doi.org/10.1016/S0140-6736\(71\)92303-8](https://doi.org/10.1016/S0140-6736(71)92303-8)

Bernardini, D. (2022). Sobre los aspectos económicos de la Diabetes mellitus. *Revista Cubana de Alimentación y Nutrición*, 30(2), 7.

<https://revalnutricion.sld.cu/index.php/rcan/article/view/1226>

Cardona-Arias, J. A., & Llanes-Agudelo, O. M. (2013). Hipertensión arterial y sus factores de riesgo en indígenas Emberá-Chamí. *CES Medicina*, 27(1), 31–43.

<http://www.redalyc.org/articulo.oa?id=261128621004>

Eghbali-Zarch, M., & Masoud, S. (2024). Application of machine learning in affordable and accessible insulin management for type 1 and 2 diabetes: A comprehensive review.

Artificial Intelligence in Medicine, 151. <https://pubmed.ncbi.nlm.nih.gov/38632030/>

García-Peña, Á. A., et al. (2022). Prevalencia de hipertensión arterial en Colombia: Revisión sistemática y meta-análisis. *Revista Colombiana de Cardiología*, 29(1), 29–35.

<https://doi.org/10.24875/RCCAR.M22000114>

Gelvez, L. (2025). Visualización interactiva: Análisis bibliográfico de aplicaciones de inteligencia artificial en el diagnóstico y predicción de diabetes e hipertensión [Aplicación web]. Generado con Claude AI (Anthropic).

<https://claude.ai/public/artifacts/19c773c7-ba0f-4514-8acc-2e6a78f7896b>

(Referencia basada en el identificador de BMJ). (2022). Global burden of type 2 diabetes in adolescents and young adults, 1990–2019: Systematic analysis of the Global Burden of Disease Study 2019. *BMJ*, 379, e072385. <https://doi.org/10.1136/bmj-2022-072385>

(Referencia basada en el DOI de Scientific Reports). (2021). [Artículo sobre diagnóstico de diabetes mediante imágenes de la lengua]. *Scientific Reports*.

<https://doi.org/10.1038/s41598-021-03879-4>

- Howlader, K. C., Satu, M. S., Awal, M. A., et al. (2022). Machine learning models for classification and identification of significant attributes to detect type 2 diabetes. *Health Information Science and Systems*, 10(2). <https://doi.org/10.1007/s13755-021-00168-2>
- Kavakiotis, I., Tsave, O., Salifoglou, A., Maglaveras, N., Vlahavas, I., & Chouvarda, I. (2017). Machine Learning and Data Mining Methods in Diabetes Research. *Computational and Structural Biotechnology Journal*, 15, 104–116. <https://doi.org/10.1016/j.csbj.2016.12.005>
- Kruczkowski, M., Drabik-Kruczkowska, A., Marciniak, A., et al. (2022). Predictions of cervical cancer identification by photonic method combined with machine learning. *Scientific Reports*, 12(1), 3762. <https://doi.org/10.1038/s41598-022-07723-1>.
- Mejía, J. A., Oviedo-Benálcazar, M. A., Ordoñez, J. A., & Valencia, J. F. (2023). Aprendizaje automático aplicado a la predicción de diabetes mellitus, utilizando información socioeconómica y ambiental de usuarios del sistema de salud. *Revista Facultad Nacional de Salud Pública*, 41(2), e351168. <https://doi.org/10.17533/udea.rfnsp.e351168>
- Mercaldo, F., Nardone, V., & Santone, A. (2017). Diabetes Mellitus Affected Patients Classification and Diagnosis through Machine Learning Techniques. *Procedia Computer Science*, 112, 2519–2528. <https://doi.org/10.1016/j.procs.2017.08.193>
- Organización Mundial de la Salud. (2016). Informe mundial sobre la diabetes. OMS. <https://iris.who.int/server/api/core/bitstreams/4865f47b-6539-408a-8862-4c7f4684c887/content>
- Pinilla Roa, A. E., Lancheros Páez, L., Viasus Pérez, D. F., et al. (s.f.). Guía 17: Guía de atención de la diabetes mellitus tipo 2. Programa de Apoyo a la Reforma de Salud

(PARS). https://www.med-informatica.net/TERAPEUTICA-STAR/DiabetesTipo2_GuiaAntencionMPS_guias17.pdf

Rohlfing, C. L., Wiedmeyer, H. M., Little, R. R., England, J. D., Tennill, A., & Goldstein, D. E. (2002). Defining the relationship between plasma glucose and HbA(1c): analysis of glucose profiles and HbA(1c) in the Diabetes Control and Complications Trial. *Diabetes Care* 25: 275-8. <https://doi.org/10.2337/diacare.25.2.275>

Satheeskumar, R., (2025). Machine learning-driven identification of the honeymoon phase in pediatric type 1 diabetes and optimizing insulin management. *Journal of Clinical Research in Pediatric Endocrinology*, 17(3), 278-287. <https://doi.org/10.4274/jcrpe>

Smith, J. W., Everhart, J. E., Dickson, W. C., Knowler, W. C., & Johannes, R. S. (1988). Using the ADAP learning algorithm to forecast the onset of diabetes mellitus. En *Proceedings of the Annual Symposium on Computer Application in Medical Care*. American Medical Informatics Association, 261. https://gerbil.phys.uvic.ca/~karun/UVic_ACML/Smith1988.pdf

Wen, J., Liu, D., Wu, Q., Zhao, L., Iao, W. C., & Lin, H. (2023). Retinal image-based artificial intelligence in detecting and predicting kidney diseases: Current advances and future perspectives. *VIEW*, 4, 202100705. <https://doi.org/10.1002/VIW.202100705>

Zurique Sánchez, M. S., Zurique Sánchez, C. P., Camacho López, P. A., Sanchez Sanabria, M., & Hernández Hernández, S. C. (2019). Prevalencia de hipertensión arterial en Colombia: Revisión sistemática y meta-análisis. *Acta Médica Colombiana*, 44(4). <https://doi.org/10.36104/amc.2019.1293>