

ppi 201502ZU4645

Esta publicación científica en formato digital es continuidad de la revista impresa  
ISSN-Versión Impresa 0798-1406 / ISSN-Versión on line 2542-3185 Depósito legal pp  
197402ZU34

# CUESTIONES POLÍTICAS

Instituto de Estudios Políticos y Derecho Público "Dr. Humberto J. La Roche"  
de la Facultad de Ciencias Jurídicas y Políticas de la Universidad del Zulia  
Maracaibo, Venezuela



Vol.43

Nº 82

Enero

Junio

2025

# Modelos predictivos en la Salud Pública: El abordaje de la diabetes mediante la Inteligencia Artificial

**Pablo Roberto Aparicio-Montenegro** \*

**Manuel Guillermo Narro Andrade** \*\*

**César Gerardo León-Velarde** \*\*\*

**Guillermo Pastor Morales Romero** \*\*\*\*

**Silvia Milagros Fernández-Flores** \*\*\*\*\*

## Resumen

El artículo tuvo como objetivo desarrollar una aplicación basada en la inteligencia artificial, cuya finalidad es la detección y atención temprana de la diabetes mellitus tipo 2, una enfermedad que afecta al 9.3% de los adultos a nivel global. Metodológicamente, se empleó un enfoque cuantitativo no experimental, haciendo uso de un conjunto de datos de 800 pacientes, de los que se seleccionaron 160 para entrenar un modelo predictivo, implementando algoritmos de machine learning, tales como K-Nearest Neighbors (KNN) y Random Forest (RF), que facilitaron el análisis de datos clínicos y biométricos. Entre los principales resultados se destaca que el modelo KNN evidenció una precisión del 95,5%, mientras que RF demostró un 92.16% de precisión. Asimismo, la regresión logística alcanzó una precisión del 79,33%. Estos modelos identificaron la glucosa como el factor predictivo más significativo, con una correlación de 0.49 respecto a la diabetes. Se concluyó que el uso de modelos de Inteligencia

\* Ingeniero Industrial, Maestro en Ingeniería de Sistemas, Especialista en Inteligencia Artificial, Simulación, Ciberseguridad e Investigación, Doctorando en Ingeniería en Sistemas. Profesor e investigador de la Universidad Nacional Federico Villarreal, Lima, Perú. ORCID ID: <https://orcid.org/0000-0001-6034-9536>. Email: [paparico@unfv.edu.pe](mailto:paparico@unfv.edu.pe)

\*\* Ingeniero de Sistemas Maestro en Administración y Dirección de Empresas, Magister en Ingeniería de Sistemas, mención en Gerencia de Tecnología de la Información. Profesor e investigador de la Universidad Nacional Federico Villarreal, Lima, Perú. ORCID ID: <https://orcid.org/0000-0001-6762-2136>. Email: [mnarro@unfv.edu.pe](mailto:mnarro@unfv.edu.pe)

\*\*\* Licenciado en Educación: Filosofía, Magister en Educación: Medición y Evaluación de la Calidad Educativa, Magister en Gestión de la Educación, Doctor en Educación. Profesor e investigador de la Universidad Nacional Federico Villarreal, Lima, Perú. ORCID ID: <https://orcid.org/0000-0002-8273-1995>. Email: [cleon@unfv.edu.pe](mailto:cleon@unfv.edu.pe)

\*\*\*\* Ingeniero en Sistemas, Licenciado en Matemática e Informática, Abogado, Especialista en Auditoría Informática, Especialista en Educación Básica Alternativa, Magister en Gestión Educacional, Magister en Gestión Pública, Magister en Ingeniería de Sistemas, Doctor en Ciencias de la Educación. Profesor e investigador de la Universidad Nacional de Educación Enrique Guzmán y Valle, Lima, Perú. ORCID ID: <https://orcid.org/0000-0002-5686-7661>. Email: [gmorales@une.edu.pe](mailto:gmorales@une.edu.pe)

\*\*\*\*\* Ingeniera en Computación e Informática, Magister en Educación: Docencia Virtual, Doctoranda en Educación. Docente e investigadora de la Universidad de San Martín de Porres, Lima, Perú. ORCID ID: <https://orcid.org/0000-0002-0626-9647>. Email: [sfernandez@usmpvirtual.edu.pe](mailto:sfernandez@usmpvirtual.edu.pe)

Artificial constituye una forma eficaz, accesible, no intrusiva y económica para facilitar la detección y atención temprana de la diabetes, mejorando la calidad en la atención personalizada, demostrando los beneficios que se pueden alcanzar en materia de salud pública.

**Palabras clave:** diabetes; inteligencia artificial; salud pública; machine learning; deep learning.

## **Predictive Models in Public Health: The Approach to Diabetes using Artificial Intelligence**

### **Abstract**

This paper aimed to develop an application based on artificial intelligence, whose purpose is the early detection and care of type 2 diabetes mellitus, a disease that affects 9.3% of adults globally. Methodologically, a non-experimental quantitative approach was used, making use of a dataset of 800 patients, from which 160 were selected to train a predictive model, implementing machine learning algorithms, such as K-Nearest Neighbors (KNN) and Random Forest (RF), which facilitated the analysis of clinical and biometric data. Among the main results, the KNN model showed an accuracy of 95.5%, while RF showed 92.16% accuracy. Likewise, logistic regression achieved an accuracy of 79.33%. These models identified glucose as the most significant predictor, with a correlation of 0.49 with respect to diabetes. It was concluded that the use of Artificial Intelligence models constitutes an effective, accessible, non-intrusive and economical way to facilitate early detection and care of diabetes, improving the quality of personalized care, demonstrating the public health benefits that can be achieved.

**Keywords:** diabetes; artificial intelligence; public health; machine learning; deep learning.

### **Introducción**

La diabetes es una enfermedad crónica que afecta a una gran cantidad de personas a nivel mundial durante un periodo prolongado de tiempo (Ong et al., 2023). Además, se identifica por la existencia de altos niveles de glucosa, lo que puede provocar una serie de complicaciones graves, como enfermedades cardíacas, problemas renales, daño a los nervios y ceguera. (Morelli et al., 2023). En este contexto, la diabetes mellitus tipo 2 (DM2)

es una de las principales causas de mortalidad en el mundo y su detección temprana es clave para la prevención de complicaciones. La Organización Mundial de la Salud (OMS) estima que el número de personas con diabetes ha aumentado drásticamente en las últimas décadas, lo que plantea la necesidad de métodos más efectivos para su detección y manejo (Ahmad et al., 2023).

Según datos estadísticos ofrecidos por la International Diabetes Federation (IDF, 2021), para el año 2021 existían al menos 537 millones de personas, en edades de entre 20 a 79 años que padecían de esta enfermedad, representando al 9.3% de adultos en edades comprendidas de 20 a 79 años (Morelli et al., 2023). Esto representa el 9.3% de la población mundial en este grupo de edad y se prevé un crecimiento a 643 Millones de personas diabéticas a nivel mundial para el año 2030 y 783 millones para el año 2045. Al respecto, Zarora & Simmons (2023) afirman que la DM2 es responsable del 90% de la totalidad de los casos de diabetes.

Como puede apreciarse, la incidencia de diabetes sigue aumentando, aunque se han logrado progresos en cuanto a su tratamiento y prevención (Valabhji et al., 2022). Por esta razón, detectar tempranamente el riesgo de desarrollar diabetes es fundamental para prevenir y tratar la enfermedad de manera efectiva. En la actualidad, existen varias herramientas y exámenes médicos que se usan para estimar su riesgo en personas, como la prueba de aceptación a la glucosa, la prueba de hemoglobina A1C y medición del índice de masa corporal (Davidson et al., 2021). Sin embargo, estas herramientas pueden resultar costosas, intrusivas y no se encuentran disponibles en todos los espacios de la salud pública.

En virtud de lo anterior, el artículo propone el diseño de una aplicación basada en inteligencia artificial, cuya finalidad consiste en facilitar la detección temprana de la diabetes en personas con factores de riesgo. La aplicación utiliza un modelo predictivo avanzado que integra datos sobre el historial familiar de diabetes, el índice de masa corporal, edad, actividad física y otros factores de riesgo. Asimismo, combina estos factores para generar una predicción con alto porcentaje de confiabilidad sobre el riesgo de desarrollar diabetes en un individuo.

Esta aplicación es una herramienta valiosa para los profesionales de la salud, así como para las personas interesadas en su propio bienestar. Con su facilidad de uso y accesibilidad, permite a las personas monitorear su riesgo de desarrollar diabetes y tomar medidas preventivas tempranamente. Además, puede resultar beneficiosa para auxiliar a los expertos de la salud en la detección de individuos con mayor probabilidad de desarrollar la enfermedad y ofrecerles intervenciones preventivas personalizadas.

## 1. Fundamentos teóricos

La diabetes mellitus, particularmente la DM2, se constituye como una de las enfermedades crónicas con mayor incidencia negativa a lo largo del mundo, teniendo un impacto drástico sobre la salud pública. Organismos internacionales como la Organización Mundial de la Salud, indican que el número de personas que padecen esta patología se ha venido aumentando considerablemente en las últimas décadas, lo que ha derivado en la investigación de distintos métodos para su manejo y detección (Kodama et al., 2022),

En este contexto, la inteligencia artificial (IA) se presenta como una herramienta, que puede servir para mejorar predecir y ofrecer un tratamiento efectivo para esta enfermedad. De acuerdo con Gautier et al. (2021), la inteligencia artificial ha tenido un impacto significativo en la vida humana, gracias a la disponibilidad de diversas plataformas médicas y métodos computacionales basados en *machine learning* (ML) y *deep learning* (DL), con un enfoque específico para desarrollar modelos predictivos y herramientas impulsadas por la inteligencia artificial, destinadas a la detección de enfermedades (Gupta et al., 2022).

La técnica de *machine learning* se destaca como una herramienta ampliamente utilizada, permitiendo a los sistemas inteligentes construir modelos apropiados mediante el aprendizaje y la identificación de patrones en los datos (Sonko et al., 2023). Para ello, resulta fundamental disponer de conjuntos de datos adecuados destinados al entrenamiento y la validación.

Empero, aunque el *machine learning* y el *deep learning* han demostrado ser herramientas versátiles y efectivas en la detección y manejo de esta patología, resulta imprescindible destacar que cada una de estas técnicas se encuentra sujeta a sus propios alcances. El *machine learning* es significativamente útil para la detección de patrones de conjuntos y datos estructurados, mientras que el *deep learning* se especializa en el análisis de datos no estructurados, como los ofrecidos en imagenología.

Según Ahmed et al. (2022), la complementariedad de estas técnicas ha impulsado la creación de modelos predictivos más precisos para atender distintas enfermedades, incluyendo la DM2. En este contexto, se presenta como un enfoque innovador basado en el promedio ponderado (Nuankaew et al., 2021). Asimismo, se han observado resultados más prometedores en otras aplicaciones al combinar varias técnicas de *machine learning*, donde la inclusión de la lógica difusa ha destacado como un método constructivo (Ahmed et al., 2022).

Morales-Martínez et al. (2020), indican que el uso de herramientas cognitivas electrónicas permite evaluar el estado del conocimiento médico en pacientes, facilitando la identificación de dificultades en la estructuración

y consolidación de la información anatómica. En el campo de la medicina, la inteligencia artificial ha tenido un gran impacto en las personas; por ello, se han desarrollado diversas plataformas médicas y métodos computacionales basados en *machine learning* y *deep learning*

En este contexto, el *machine learning* es una técnica ampliamente utilizada para construir modelos inteligentes mediante la extracción de patrones en los datos. El uso de conjuntos de datos apropiados y técnicas de *machine learning*, como la lógica difusa, ha demostrado resultados prometedores en la predicción de la DM2 (Nuankaew et al., 2021 y Ahmed et al., 2022).

De acuerdo con Yelsin & Malpartida (2022), la diabetes representa una seria amenaza para la salud pública, debido a la elevada concentración de glucosa en el organismo humano. Por lo tanto, un diagnóstico temprano desempeña un papel esencial en el tratamiento y la prevención de las complicaciones asociadas. Raffali y Mohd Asraf (2023), destacan la relevancia de la adopción de un estilo de vida saludable, que incluye una dieta equilibrada y la actividad física, como medidas esenciales para prevenir la DM2, especialmente entre los jóvenes, debido al aumento alarmante de la obesidad infantil. Estos posicionamientos teóricos son compartidos por Ramírez et al. (2019), quienes subrayan que la diabetes, combinada con la obesidad, conocida como «diabesidad», representa un problema estructural en la población latina, siendo necesario implementar estrategias educativas y culturalmente relevantes para abordar estos problemas.

En cuanto a los modelos los modelos predictivos de la inteligencia artificial se utilizan en diversas áreas para prever resultados futuros, optimizar procesos, y tomar decisiones informadas. Son especialmente útiles cuando se cuenta con grandes volúmenes de datos y patrones complejos que no son evidentes para los métodos tradicionales de análisis (Aldoseri et al., 2023). Entre ellos se consideran:

- ***KNN (vecinos más cercanos)***: El modelo K-Nearest Neighbors (KNN) es un método de aprendizaje supervisado que clasifica datos basándose en la similitud con sus “k” vecinos más cercanos, siendo particularmente útil en problemas de clasificación y regresión donde no se tiene un modelo paramétrico claro. Esta técnica es ampliamente utilizada en aplicaciones como reconocimiento de patrones y diagnóstico médico debido a su simplicidad y eficiencia (Li et al., 2020).
- ***RF (Random Forest)***: se define como un conjunto de árboles de decisión que se utiliza tanto para problemas de clasificación como de regresión. Este algoritmo combina las predicciones de múltiples árboles para mejorar la precisión y controlar el sobreajuste, manejando datasets de tamaño pequeño a mediano y

proporcionando soluciones efectivas en diversos contextos, como la identificación de objetos y la evaluación de riesgos crediticios.

- **LR (Logistic Regression):** se concibe como un método estadístico ampliamente utilizado para predecir resultados binarios. En el contexto de la inteligencia artificial, LR permite modelar la relación entre una variable dependiente binaria y una o más variables independientes mediante el cálculo de probabilidades. Este modelo es especialmente relevante para predicciones de diagnóstico, donde su optimización y precisión son clave para mejorar las decisiones clínicas (Boateng & Abaye, 2019).

Además de los modelos antes citados, otras técnicas de la inteligencia artificial han sido útiles para la predicción de la diabetes, como el uso de neuronas convolucionales para el tratamiento de la retinopatía diabética, puesto que estas redes detectan patrones en las imágenes que pueden ser signos distintivos de la enfermedad, lo que brinda la posibilidad de un diagnóstico temprano y asertivo.

En este orden de ideas, Hennebelle et al. (2023) propusieron “HealthEdge”, un marco de atención médica inteligente basado en *machine learning* para la predicción de la DM2, integrando sistemas de IoT, edge y *cloud computing*. Este enfoque demostró una precisión superior en comparación con métodos tradicionales, destacando la eficacia del *Random Forest* (RF) sobre la Regresión Logística (LR).

Asimismo, Mohsen et al. (2023) realizaron una revisión exhaustiva de modelos basados en la inteligencia artificial para la predicción del riesgo de DM2, señalando que los modelos multimodales que integran múltiples fuentes de datos superan en rendimiento a los unimodales. En este contexto, el uso de la inteligencia artificial y el *machine learning* ha adquirido relevancia, pues estos modelos pueden analizar grandes volúmenes de datos y predecir con precisión el riesgo de desarrollar DM2 (Kopitar et al., 2023). A esto se suma la posibilidad de identificar patrones ocultos en los datos clínicos y biométricos, proporcionando herramientas más precisas y accesibles para la detección de esta enfermedad (Deberneh & Kim, 2023).

De igual forma, Kopitar et al. (2023) desarrollaron modelos basados en *deep learning*, los cuales demostraron un desempeño superior en comparación con métodos tradicionales. Además, Deberneh y Kim (2023) implementaron una arquitectura de redes neuronales para la clasificación de pacientes con alto riesgo de DM2, alcanzando una precisión superior al 90 %.

En otro estudio, Ahmad et al. (2023) utilizaron árboles de decisión y *Random Forest* (RF), logrando identificar factores de riesgo clave como el índice de masa corporal (IMC), los niveles de glucosa y la presión arterial. Estas investigaciones destacan el potencial de la IA para mejorar la precisión y rapidez en el diagnóstico de DM2.

Como puede apreciarse, el avance de la inteligencia artificial en la salud pública ha permitido la integración de modelos predictivos con sistemas de Internet de las Cosas (IoT) y computación en la nube. Hennebelle et al. (2023) propusieron el marco “HealthEdge”, un sistema inteligente basado en *machine learning* que combina *IoT* y *edge computing* para la detección de DM2 en tiempo real. Este enfoque permite una recopilación eficiente de datos desde dispositivos médicos portátiles, los cuales son procesados de manera inmediata, optimizando la toma de decisiones clínicas.

Por otro lado, la combinación de *deep learning* con análisis de imágenes médicas, mejora la detección de señales tempranas de DM2 en pruebas oftalmológicas y resonancias magnéticas (Kowsher et al., 2023). A pesar de estos avances, existen desafíos en la implementación clínica de estos modelos. La calidad y disponibilidad de los datos clínicos, la interoperabilidad entre sistemas y la interpretabilidad de los modelos de IA siguen siendo aspectos críticos (Mosquera et al., 2023).

Sin embargo, se ha demostrado que la combinación de múltiples algoritmos de *machine learning* puede mejorar significativamente la precisión diagnóstica, reduciendo el margen de error en la clasificación de pacientes (Hoyos et al., 2023). En este sentido, la integración de IA en la atención médica no solo facilita la detección temprana de DM2, sino que también optimiza la asignación de recursos al sector de la salud pública, mejorando la calidad de vida de los pacientes, fomentando un enfoque participativo entre investigadores, médicos, tecnólogos, instituciones públicas, privadas y el Estado.

## 2. Materiales y métodos

La investigación es de enfoque cuantitativo, puesto que se caracteriza por el análisis de datos cuantificables para obtener conclusiones sobre la precisión y rendimiento de un modelo predictivo. Este enfoque posibilita medir de manera objetiva el funcionamiento del modelo a través de métricas exactas, precisas y específicas. Asimismo, es de naturaleza no experimental, debido a que no se manipulan variables en los sujetos ni se interviene para observar sus efectos en los resultados, sino que se validan en el rendimiento de un modelo con datos preexistentes (Fang et al., 2020). Dicho modelo es adecuado para estudios que procuran evaluar la eficacia de modelos predictivos sin alterar los datos. Por lo tanto, la investigación es de corte transversal, validada en el modelo de predicción basado en IA en un solo conjunto de datos en un momento puntual

Abarca un enfoque nacional como internacional, integrando el análisis de datos clínicos y biomédicos de pacientes diagnosticados con diabetes y de aquellos sin dicha condición. Los datos considerados han sido recolectados

durante los últimos siete años, proporcionando una base sólida y diversa para el desarrollo y la validación de modelos predictivos de inteligencia artificial.

El universo de estudio de esta investigación está constituido por datos clínicos y biométricos de diabetes recopilados de 800 pacientes. Estos datos se obtuvieron de un dataset disponible públicamente en Kaggle, una plataforma reconocida por compartir datos científicos para uso de investigadores. La muestra corresponde al 20% del total equivalente a 160 datos clínicos y biométricos que se utilizarán para el entrenamiento del modelo. El tamaño de la muestra obedece a prácticas comunes en el *machine learning*, donde es recomendable reservar 20% o 30% de los datos para validar las pruebas. Por ende, la evaluación del modelo se llevará a cabo con los datos de 7 pacientes, que fueron seleccionados para determinar la precisión en la predicción.

La unidad de análisis de este estudio son los datos clínicos y biomédicos de pacientes con y sin diagnóstico de diabetes. Estos datos incluyen variables como edad, género, antecedentes familiares de diabetes, nivel de glucosa, presión arterial, índice de masa corporal (IMC), entre otros factores de riesgo y características relevantes para la predicción de diabetes.

Para el preprocesamiento de la data, limpieza, entrenamiento, validación y evaluación del modelo propuesto se utilizó Python®3.8, con las librerías Pandas, NumPy y Plotly, y la aplicación web Jupyter Notebook para la codificación del modelo. Como técnica de análisis, se utilizó el análisis documental y como instrumento la ficha de registros digital para la recolección de datos. Asimismo, se emplea la técnica de observación directa con el objetivo de analizar los datos y proporcionar la interpretación proporcionada por el sistema

En cuanto a su procedimiento, la investigación hará uso de la *deep learning* para la generación de un modelo que sirva para ser utilizado en la predicción de la diabetes, considerando los siguientes elementos:

- Importación de librerías basadas en IA
- Recopilación de datos
- Describir y resumir los datos.
- Depuración de datos
- División de la data para entrenamiento y pruebas.
- Escalado
- Creación del Modelo para la predicción de la diabetes
- Generar un servicio Web Service usando Base datos MySQL
- Implementar el modelo en una aplicación móvil

Considerando lo anterior, se destaca la urgencia de contar con un método de diagnóstico de la diabetes que sea fácil y rápido. Evaluar el impacto de los modelos de *machine learning* seleccionados utilizando atributos médicos se vuelve esencial. En este contexto, se han desarrollado y probado 13 métodos de *machine learning*, que incluyen modelos clásicos, redes neuronales y modelos, con el objetivo de predecir la diabetes.

Los datos utilizados fueron recopilados en el Policlínico Leo SAC de San Juan de Lurigancho. La evaluación de los modelos predictivos se realizó mediante métricas como la exactitud, precisión y especificidad, tanto en el conjunto de datos de entrenamiento como en el de prueba.

### 3. Resultados y discusión

Los análisis realizados con el modelo K-Nearest Neighbors (KNN) arrojaron una precisión del 95.5 %, confirmando su efectividad en la identificación de patrones asociados al riesgo de diabetes. Este resultado destaca la importancia de utilizar algoritmos basados en similitudes, especialmente en conjuntos de datos clínicos complejos.

Estudios recientes han respaldado estas observaciones, señalando que los modelos de *machine learning* como KNN pueden superar a métodos tradicionales al identificar características no lineales en los datos (Silva, Martins, & Sampaio, 2023). Asimismo, la precisión del modelo Random Forest (RF), con un 92.16 %, demuestra su capacidad para manejar datos diversos, lo que lo convierte en una herramienta robusta para la predicción médica (Ahmed et al., 2022).

Por otro lado, el modelo de regresión logística (LR) obtuvo una precisión del 79.33 %, lo que, aunque menor en comparación con KNN y RF, reafirma su utilidad en el análisis de relaciones lineales entre variables predictivas. Este hallazgo coincide con investigaciones previas que destacan la aplicación de LR en la identificación de factores de riesgo clave para enfermedades crónicas, como la diabetes (Boateng & Abaye, 2019). No obstante, su desempeño limitado frente a algoritmos más avanzados subraya la necesidad de optimizar su implementación en aplicaciones predictivas complejas.

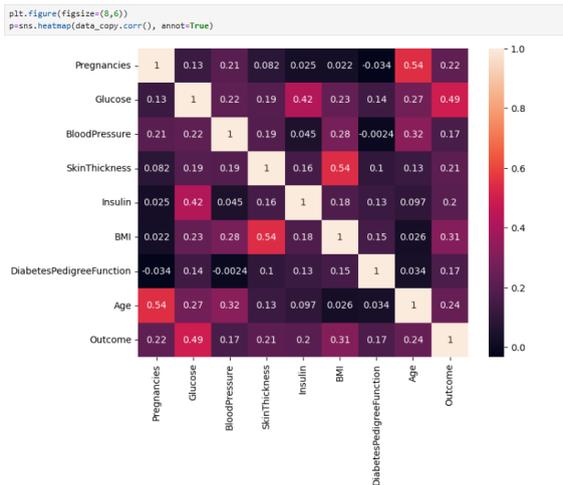
El análisis de las variables predictivas demostró que la glucosa es el factor de mayor incidencia en el desarrollo de diabetes, con una correlación significativa de 0.49 respecto al resultado clínico. Este hallazgo refuerza la importancia de incluir esta variable como un componente esencial en modelos predictivos. Investigaciones recientes han identificado el índice de masa corporal (IMC) y la presión arterial como factores secundarios importantes, sugiriendo un enfoque multimodal para aumentar la

precisión diagnóstica (Hennebelle, Materwala, & Ismail, 2023). Además, la integración de tecnologías de IoT y edge computing ha demostrado mejorar la recolección y procesamiento de datos en tiempo real, optimizando la precisión de los modelos predictivos (Kopitar et al., 2023).

Desde una perspectiva práctica, la implementación de esta herramienta basada en inteligencia artificial no solo facilita la predicción temprana de la diabetes, sino que también representa un avance en la accesibilidad y personalización de la atención médica. La combinación de algoritmos como KNN y RF, junto con sistemas inteligentes, permite intervenciones preventivas más efectivas, reduciendo los costos y mejorando la calidad de vida de los pacientes. Estos resultados confirman el potencial de la IA en la medicina preventiva y abren nuevas oportunidades para su aplicación en otros campos clínicos (Deberneh & Kim, 2023).

Utilizando la función Seaborn, que permite crear gráficos estadísticos, facilitando la visualización de patrones, relaciones y distribuciones en datos de salud, como el nivel de glucosa, el índice de masa corporal (IMC) y la presión arterial, que son variables predictivas comunes en modelos de diagnóstico de diabetes (Silva et al., 2023), se muestran las combinaciones de los datos. El color naranja representa a las personas que tienen diabetes y el color azul a las personas que no tienen diabetes, lo que indica que el parámetro principal es la glucosa, teniendo mayor incidencia en la predicción de la diabetes.

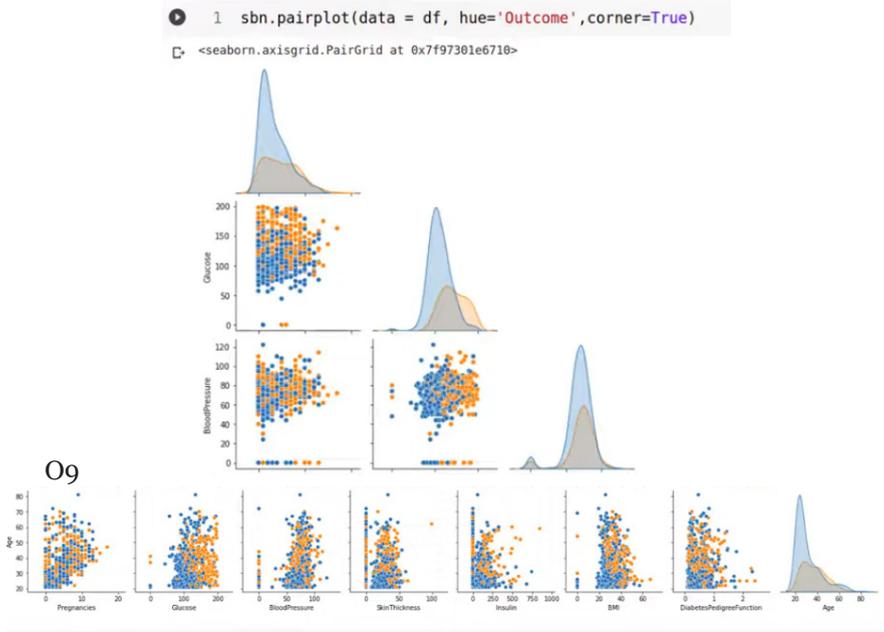
**Imagen 1. Mapa de correlación de variables**



Fuente: elaboración propia (2025).

La matriz de heatmap (o mapa de calor) es una representación visual de datos que muestra valores en una matriz o tabla de manera que las diferencias en los valores se indican mediante variaciones de color. En un contexto de análisis de datos, los heatmaps se utilizan para visualizar la correlación entre variables, observar patrones y detectar relaciones en grandes volúmenes de datos de manera rápida e intuitiva, se observa alta correlación en la variable objetivo: Outcome y la variable Glucosa con un valor de 0.49

**Imagen 2. Correlación de variables.**



**Fuente:** elaboración propia (2025).

Los resultados demuestran que, al aplicar algoritmos de clasificación, como K-Nearest Neighbors (KNN), Random Forest (RF) y Logistic Regression (LR), se pueden alcanzar precisiones significativas en la predicción de la diabetes, lo cual valida la utilidad de estos modelos en el contexto clínico.

El modelo KNN mostró la mayor precisión con un 95.50%, seguido de RF con un 92.16%, lo que sugiere que estos algoritmos, al ser menos propensos al sobreajuste y al aprovechar la variabilidad en los datos,

son particularmente útiles en la identificación de patrones complejos en conjuntos de datos clínicos. La precisión menor obtenida en el modelo LR (79.33%) puede deberse a su naturaleza estadística lineal, que puede limitar su capacidad para capturar relaciones no lineales presentes en datos biomédicos.

Un hallazgo relevante es la importancia de la variable de glucosa, que muestra una correlación alta con el riesgo de desarrollar diabetes, según el análisis de correlación en el heatmap. Esto coincide con estudios previos, que destacan a la glucosa como un factor crítico en modelos predictivos de diabetes, reforzando la relevancia de utilizar esta variable en futuras aplicaciones para una mayor precisión y sensibilidad en el diagnóstico.

Desde una perspectiva práctica, la aplicación propuesta contribuye a la accesibilidad en la evaluación del riesgo de diabetes, brindando a pacientes y profesionales de la salud una herramienta preventiva con un bajo costo y de fácil implementación. Además, esta solución tecnológica permite intervenciones tempranas y personalizadas en personas en riesgo, reduciendo el potencial impacto de la diabetes en su calidad de vida y la carga económica en el sistema de salud pública.

## Conclusiones

La investigación ha implementado un modelo de inteligencia artificial para la predicción y atención temprana de DM2. Los resultados demuestran su viabilidad y precisión, con un rendimiento notorio del 95,50% en el modelo en el modelo K-Nearest Neighbors (KNN) y del 92.16% en Random Forest (RF), lo que deja en claro que el uso de algoritmos e inteligencia artificial constituyen alternativas superiores frente a las técnicas tradicionales de diagnóstico, con el añadido de ser económicas, no invasivas y de fácil acceso.

En este contexto, la glucosa fue señalada como el factor predictivo más importante, denotando su relevancia para la construcción de los modelos diagnósticos, basados en la prevención, reducción de riesgos y atención temprana de los pacientes. Por este motivo, puede afirmarse que la integración de la inteligencia artificial al tratamiento y diagnóstico de la DM2 es un avance revolucionario en lo que se concibe como medicina preventiva, conduciendo a oportunidades para su aplicación y manejo en el campo de la salud pública y en la atención de distintas enfermedades crónicas, fomentando el avance de la ciencia, así como el desarrollo de tecnologías clínicas eficientes y personalizadas.

En virtud de lo anterior, se recomienda la ampliación de bases de datos, incluyendo registro de pacientes provenientes de distintas latitudes geográficas y de entornos culturales diversos, lo que contribuiría a fortalecer

la generalización que ofrecen los modelos predictivos, siendo aplicados a poblaciones heterogéneas. Por ello, es pertinente validar los distintos modelos en instituciones sanitarias diferentes, utilizando el entrenamiento para que los resultados sean precisos y eficientes, comparándose permanentemente con herramientas existentes en el mercado, identificando sus alcances, costos y soluciones que ofrecen en el tratamiento de la DM2.

Finalmente, se vislumbra que la aplicación de técnicas provenientes del *machine learning*, *deep learning* y de las neuronales convolucionales, revolucionará la atención médica, mejorando la precisión en el diagnóstico y tratamiento de enfermedades. Ello requiere de la capacitación constante de los profesionales de la salud en el uso de distintas aplicaciones de la inteligencia artificial, impulsando su uso continuo en la práctica médica.

### Referencias bibliográficas

- AHMED, Usama; ISSA, Ghassan F; KHAN, Muhammad; AFTAB, Shabib; KHAN, Muhammad; SAID, Raed; GHAZAL, Taher; AHMAD, Munir. 2022. "Prediction of Diabetes Empowered with Fused Machine Learning" En: IEEE Access. No. 10, pp. 8529–8538. Disponible en línea. En: <https://doi.org/10.1109/ACCESS.2022.3142097>. Fecha de consulta: 10 de octubre de 2024.
- ALDOSERI, Abdulaziz; AL-KHALIFA, Khalifa; HAMOUDA, Abdel. 2023. "Re-thinking data strategy and integration for artificial intelligence: Concepts, opportunities, and challenges" En: Applied Sciences. Vol. 13, No. 12, pp. 7082. Disponible en línea. En: <https://doi.org/10.3390/app13127082>. Fecha de consulta: 22 de octubre de 2024.
- BOATENG, Ernest; ABAYE, Daniel. 2019. "A review of the logistic regression model with emphasis on medical research" En: Journal of Data Analysis and Information Processing. Vol. 7, No. 4, pp. 193-204. Disponible en línea. En: <https://doi.org/10.4236/jdaip.2019.74012>. Fecha de consulta: 22 de diciembre de 2024.
- DAVIDSON, K. W., BARRY, M. J., MANGIONE, C. M., CABANA, M., CAUGHEY, A. B., DAVIS, E. M., & WONG, J. B. 2021. "Screening for Prediabetes and Type 2 Diabetes: US Preventive Services Task Force Recommendation Statement!" En: JAMA. Vol. 326, No. 8, pp. 736–743. Disponible en línea. En: <https://doi.org/10.1001/jama.2021.12538>. Fecha de consulta: 22 de diciembre de 2024.
- DEBERNEH, Henock; KIM, Intaek. 2023. "Prediction of Type 2 Diabetes Based on Machine Learning Algorithm in the Internet of Medical Things Environment" En: National Library of Medicine. Disponible en línea.

En: <https://pubmed.ncbi.nlm.nih.gov/33806973/>. Fecha de consulta: 22 de diciembre de 2024.

FANG, Conglong; GAI, Qingen; HE, Chaofei; SHI, Qinghua. 2020. “The Experience of Poverty Reduction in Rural China” En: SAGE Open. Disponible en línea. En: <https://doi.org/10.1177/2158244020982288>. Fecha de consulta: 22 de diciembre de 2024.

GAUTIER, Thibault; ZIEGLER, Leah B; GERBER, Matthew; CAMPOS-NÁÑEZ, Enrique; PATEK, Stephen. 2021. “Artificial intelligence and diabetes technology: A review”. En: *Metabolism: Clinical and Experimental*. Vol. 124. W.B. Saunders. Disponible en línea. En: <https://doi.org/10.1016/j.metabol.2021.154872>. Fecha de consulta: 25 de diciembre de 2024.

GUPTA, Meenu; KUMAR, Rakesh; AHMED, Shakeel; PRIYADARSHAN, Prasuryya; SHARMA, Aditya. 2022. Low Latency Packet Delivery for SOHO “Infrastructure. Proceedings of 2022 2nd International” En: Conference on Computing and Information Technology, ICCIT 2022, 65–68. Disponible en línea. En: <https://ieeexplore.ieee.org/document/9711632>. Fecha de consulta: 14 de noviembre de 2024.

HENNEBELLE, Alain; MATERWALA, Huned; ISMAIL, Leila. 2023. “HealthEdge: A Machine Learning-Based Smart Healthcare Framework for Prediction of Type 2 Diabetes in an Integrated IoT, Edge, and Cloud Computing System” En: *Procedia Computer Science*. Vol. 220, pp. 331-338. Disponible en línea. En: <https://doi.org/10.1016/j.procs.2023.03.043>. Fecha de consulta: 15 de marzo de 2024.

HOYOS, William; HOYOS, Kenia; RUIZ-PÉREZ, Rander. 2023. “Modelo de inteligencia artificial para la detección temprana de diabetes” En: *Biomédica*. Vol. 43(Suppl 3), pp. 110-125. Disponible en línea. En: <https://doi.org/10.1186/s12902-023-01316-7>. Fecha de consulta: 19 de diciembre de 2024.

INTERNATIONAL DIABETES FEDERATION. 2021. International Diabetes Federation’s Guide for Diabetes Epidemiological Studies. Disponible en línea. En: [https://www.diabetesresearchclinicalpractice.com/article/S0168-8227\(20\)30887-1/fulltext](https://www.diabetesresearchclinicalpractice.com/article/S0168-8227(20)30887-1/fulltext). Fecha de consulta: 15 de enero de 2025.

KODAMA, Satoru; FUJIHARA, Kazuya; HORIKAWA, Chika; KITAZAWA, Masaru; IWANAGA, Midori; KATO, Kiminori; WATANABE, Kenichi; NAKAGAWA, Yoshimi; MATSUZAKA, Takashi; SHIMANO, Hitoshi; SONE, Hirohito. 2022. “Predictive ability of current machine learning algorithms for type 2 diabetes mellitus: A meta-analysis” En: *Journal of Diabetes Investigation*. Vol. 13, No. 5, pp. 900-908. Disponible en línea.

En: <https://doi.org/10.1111/jdi.13736>. Fecha de consulta: 15 de enero de 2025.

KOPITAR, L.; FORTUNA, T.; GORO, M. 2023. "Deep Learning-Based Predictive Models for Early Detection of Type 2 Diabetes Mellitus" Disponible en línea. En: <https://doi.org/10.1093/biomed/bmy120>.

KOWSHER, MD; TURABA, Mahbuba; SAJED, Tanvir; RAHMAN, M. M. M. 2023. "Prognosis and Treatment Prediction of Type-2 Diabetes Using Deep Neural Network and Machine Learning Classifiers" En: Cornell University. Disponible en línea. En: <https://arxiv.org/abs/2301.03093>. Fecha de consulta: 15 de diciembre de 2024.

MALPARTIDA, Jaime. 2022. "Predicción de diabetes mellitus tipo 2 utilizando atributos médicos del Policlínico Leo SAC de San Juan de Lurigancho mediante el enfoque de Machine Learning" En: Revista Científica. Vol. 2, No. 4, pp. 1-19.

MOHSEN, Farida; AL-ABSI, Hamada R. H; YOUSRI, Noha A; EL HAJJ, Nady; SHAH, Zubair. 2023. "Artificial Intelligence-Based Methods for Precision Medicine: Diabetes Risk Prediction" En: Cornell University. Disponible en línea. En: <https://doi.org/10.48550/arXiv.2305.16346>. Fecha de consulta: 10 de octubre de 2024.

MORALES-MARTÍNEZ, Guadalupe; ÁNGELES CASTELLANOS, Alberto; IBARRA, Víctor; MANCERA, Magaly. 2020. "Herramientas cognitivas electrónicas para diagnosticar el estado del conocimiento médico en estudiantes matriculados en una carrera" En: Revista Internacional de Aprendizaje, Enseñanza e Investigación Educativa. Vol. 19, No. 9, pp. 341-362. Disponible en línea. En: <https://doi.org/10.26803/ijlter.19.9.18>. Fecha de consulta: 14 de enero de 2025.

MORELLI, Daniela; RUBINSTEIN, Fernando; SANTERO, Marilina; GIBBONS, Luz; MOYANO, Daniela; NEJAMIS, Analia; BERATARRECHEA, Andrea. 2023. "Effectiveness of a diabetes program based on digital health on capacity building and quality of care in type 2 diabetes: a pragmatic quasi-diexperimental study" En: BMC Health Services Research. Vol. 23, No. 1. Disponible en línea. En: <https://doi.org/10.1186/s12913-023-09082-7>. Fecha de consulta: 14 de enero de 2025.

MOSQUERA, Guillermo; HERRERÍA, Julio; BONILLA, Vladimir; SÁNCHEZ, Miguel; ANDRADE, Cristina. 2023. "Prediagnóstico Médico de la Diabetes Mellitus tipo 2 mediante Machine Learning" En: *Revista Innovación Digital Y Desarrollo Sostenible – IDS*. Vol. 3, No. 2, pp. 65-69. Disponible en línea. En: <https://revistas.iudigital.edu.co/index.php/ids/article/view/114>. Fecha de consulta: 12 de enero de 2025.

- NUANKAEW, Praty; CHAISING, Supansa; TEMDEE, Punnarumol. 2021. "Average Weighted Objective Distance- Based Method for Type 2 Diabetes Prediction" En: IEEE Access. S, pp. 137015–137028. Disponible en línea. En: <https://doi.org/10.1109/ACCESS.2021.3117269>. Fecha de consulta: 15 de septiembre de 2024.
- ONG, K. L; STAFFORD, L. K; MCLAUGHLIN, S. A; BOYKO, E. J; VOLLSET, S. E; SMITH, A. E; DALTON, B. E; ET AL. 2023. "Global, regional, and national burden of diabetes from 1990 to 2021, with projections of prevalence to 2050: A systematic analysis for the Global Burden of Disease Study 2021" En: The Lancet Diabetes & Endocrinology. Vol. 11, No. 5, pp. 420-430. Disponible en línea: [https://doi.org/10.1016/S2213-8587\(23\)00152-9](https://doi.org/10.1016/S2213-8587(23)00152-9). Fecha de consulta: 15 de septiembre de 2024.
- RAFFALI, Ana; MOHD ASRAF, Ratnawati. 2023." Fomentar los principios de mentalidad de crecimiento en la prevención de la diabetes tipo 2 mediante un juego narrativo" En: Revista Internacional de Aprendizaje, Enseñanza e Investigación Educativa. Vol. 22, No. 2, pp. 244-261. Disponible en: <https://doi.org/10.26803/ijlter.22.2.14>. Fecha de consulta: 25 de septiembre de 2024.
- RAMÍREZ, O; CARRANZA-ALVAREZ, A; MCCOLLOUGH, C. 2019. "Diabesidad entre los latinos: Una actividad matemática culturalmente relevante" En: Revista Internacional de Aprendizaje, Enseñanza e Investigación Educativa. Vol. 18, No. 4, 63-84.
- SONKO, Salleh; LAMYA, Fathima; ALZUBAIDI, Mahmood; SHAH, Hurmat; ALAM, Tanvir; SHAH, Zubair; HOUSEH, Mowafa. 2023. "Predicting Long-Term Type 2 Diabetes with Artificial Intelligence (AI): A Scoping Review" En: Studies in Health Technology and Informatics. No. 305, pp. 652–655. Disponible en línea. En: <https://doi.org/10.3233/SHTI230582>. Fecha de consulta: 25 de septiembre de 2024.
- VALABHJI, Jonathan; BARRON, Emma; DOMINIQUE, Bradley; BAKHAI, Chirag; KHUNTI, Khunti; JEBB, Susan. 2022. "Effect of the COVID-19 pandemic on body weight in people at high risk of type 2 diabetes referred to the English NHS Diabetes Prevention Programme" En: The Lancet Diabetes & Endocrinology. Vol. 9, No. 8, pp. 649-651. Disponible en línea. En: [https://doi.org/10.1016/S2213-8587\(21\)00218-7](https://doi.org/10.1016/S2213-8587(21)00218-7). Fecha de consulta: 25 de septiembre de 2024.
- ZARORA, Reetu; SIMMONS, David. 2023. "Effectiveness of Diabetes Case Conferencing Program on Diabetes Management" En: International Journal of Integrated Care. Vol. 23, No. 1-2. Disponible en línea. En: <https://pubmed.ncbi.nlm.nih.gov/36741969/>. Fecha de consulta: 25 de septiembre de 2024.



UNIVERSIDAD  
DEL ZULIA

---

# CUESTIONES POLÍTICAS

Vol.43 N° 82

*Esta revista fue editada en formato digital y publicada en abril de 2025, por el **Fondo Editorial Serbiluz**, Universidad del Zulia. Maracaibo-Venezuela*

[www.luz.edu.ve](http://www.luz.edu.ve)  
[www.serbi.luz.edu.ve](http://www.serbi.luz.edu.ve)  
[www.produccioncientificaluz.org](http://www.produccioncientificaluz.org)