

Prevención de Riesgos de la Diabetes Mediante una Plataforma Inteligente de Monitorización y Predicción de Complicaciones con Inteligencia Artificial

Fermin Cárdenas Cabal

Alejandro Ortiz Pérez

Jorge Christian Serrano Puertos

Tecnologías de la Información y
Comunicación

Tecnologías de la Información y
Comunicación

Tecnologías de la Información y
Comunicación

Universidad Tecnológica del Centro de
Veracruz

Universidad Tecnológica del Centro de
Veracruz

Universidad Tecnológica del Centro de
Veracruz

Cuitláhuac, México

Cuitláhuac, México

Cuitláhuac, México

202231001065@utcv.edu.mx

202231001025@utcv.edu.mx

202231001079@utcv.edu.mx

Abstract—La diabetes representa uno de los principales desafíos de salud pública a nivel mundial, con un impacto significativo en la calidad de vida de los pacientes y altos costos para el sistema sanitario. Este estudio tiene como objetivo desarrollar y evaluar una plataforma inteligente que monitorice en tiempo real a los pacientes diabéticos y prediga de manera temprana complicaciones asociadas a la enfermedad mediante técnicas de Inteligencia Artificial. Para ello, se diseñó una arquitectura basada en la integración de dispositivos de monitorización de parámetros fisiológicos, bases de datos clínicas y algoritmos predictivos entrenados con aprendizaje automático. Durante la fase de validación, la plataforma demostró una alta precisión en la detección de patrones que anticipan eventos críticos, permitiendo una intervención oportuna y personalizada. Los resultados preliminares sugieren que la aplicación de técnicas de IA en la monitorización continua puede mejorar significativamente la prevención de complicaciones, optimizando el tratamiento y reduciendo emergencias. En conclusión, la implementación de esta herramienta tecnológica ofrece una solución innovadora para la gestión de la diabetes, con potencial para transformar los modelos tradicionales de cuidado y mejorar la calidad de vida de los pacientes.

Keywords—Diabetes, prevención, monitorización, inteligencia artificial, aprendizaje automático, salud digital.

I. INTRODUCCIÓN

La diabetes mellitus representa una de las principales preocupaciones de salud pública en México. Según la Encuesta Nacional de Salud y Nutrición (Ensanut) 2021, aproximadamente 12.4 millones de mexicanos padecen esta enfermedad [1]. Además, la Ensanut 2022 reveló que la prevalencia total de diabetes alcanza el 18.3%, mientras que la prediabetes afecta al 22.1% de la población [2]. Estas cifras sitúan a México entre los países con mayor incidencia a nivel mundial [3]. La elevada prevalencia genera una carga significativa para el sistema de salud, siendo la diabetes la segunda causa de muerte en el país [4]. Dado que el manejo inadecuado puede derivar en complicaciones graves, es crucial implementar estrategias efectivas para la detección temprana y el monitoreo continuo. En este contexto, las tecnologías avanzadas, como los sistemas de monitoreo continuo de glucosa y las plataformas digitales, han

demostrado mejorar el control glucémico [5]. El presente trabajo tiene como objetivo desarrollar una plataforma tecnológica integral que combine aplicaciones móviles y web, inteligencia artificial y dispositivos IoT para la predicción y monitorización de la diabetes, con el fin de mejorar la comunicación entre médicos y pacientes y optimizar el seguimiento de la enfermedad.

II. TRABAJOS RELACIONADOS

La investigación en tecnologías para el manejo de la diabetes ha evolucionado hacia soluciones integradas. A continuación, se contextualizan estudios previos clave.

A. Dispositivos de monitorización continua de glucosa (MCG)

Los sistemas Dexcom G6/G7 y FreeStyle Libre 3 han demostrado precisión clínica en la detección de fluctuaciones glucémicas [3,5]. Han validado su utilidad en la prevención de hipoglucemias nocturnas mediante alertas en tiempo real, con sensibilidad del 89% [5]. Sin embargo, su integración con plataformas predictivas escalables sigue siendo un reto.

B. Plumaz de insulina inteligentes y dispositivos IoT

Dispositivos como InPen y NovoPen 6 han mejorado la adherencia al tratamiento mediante el registro automatizado de dosis [5]. No obstante, su enfoque se limita a la gestión reactiva. Wearables como Withings ScanWatch han explorado la correlación entre variabilidad cardíaca y complicaciones diabéticas, aunque con escasa integración con sistemas de IA [6].

C. Plataformas de análisis y predicción

Aplicaciones como LibreView y Glooko permiten la visualización retrospectiva de datos glucémicos [5]. Sin embargo, su arquitectura centralizada limita la escalabilidad. En contraste, estudios recientes han propuesto métodos no invasivos para la detección de diabetes mediante sensores de aliento y TinyML, aunque con menor precisión temporal [6].

D. Algoritmos de IA en predicción de riesgos

El uso de Random Forest (exactitud: 87%) y SVM (exactitud: 83%) ha sido ampliamente validado para predecir eventos glucémicos [5]. Otros trabajos han combinado datos de sensores IoT con redes neuronales para predecir riesgos cardiovasculares, aunque sin personalización de alertas clínicas [6].

E. Limitaciones y Contribuciones

Persisten brechas como la fragmentación de datos, la falta de seguridad y la baja accesibilidad en plataformas existentes [4,5]. Este trabajo supera estas limitaciones mediante una arquitectura modular (Spring Boot, Kafka), algoritmos optimizados (Random Forest) e interoperabilidad vía APIs abiertas para conectar con aplicaciones móviles (Angular, React) y bases de datos clínicas [1,3,5].

F. Motivación y Enganche

Antes de profundizar en la solución técnica, planteamos una pregunta simple a una sala de médicos y pacientes: “¿Quién aquí conoce a alguien que viva con diabetes?” Casi todas las manos se levantaron—recordándonos que la diabetes no es una estadística lejana, sino una realidad vivida en cada hogar mexicano. Sin embargo, más allá de un pinchazo en el dedo o una dosis de insulina, los pacientes cargan una incertidumbre diaria: “¿Estoy haciendo lo suficiente para prevenir complicaciones que puedan quitarme la vista, los riñones o incluso una extremidad?”

G. Planteamiento del Problema

Para ilustrar la gravedad, tan pronto como se diagnostica la diabetes, un paciente enfrenta:

- 31 % de probabilidad de desarrollar retinopatía diabética,
- 31 % de riesgo de nefropatía (daño renal),
- 20 % de probabilidad de neuropatía (daño nervioso),
- 17 % de posibilidad de pie diabético que puede llevar a una amputación.

A pesar de conocer estas cifras, nuestro paradigma actual de monitoreo es reactivo—la Hemoglobina A1c refleja solo los últimos tres meses—y las lecturas puntuales con glucómetro no cuentan la historia más rica que ofrece el monitoreo continuo de glucosa.

H. Objetivos

Sobre esta urgencia, nuestro objetivo general es desarrollar una plataforma para el monitoreo en tiempo real y la predicción temprana de complicaciones diabéticas mediante IA, mejorando así la atención al paciente y su calidad de vida. Específicamente, en esta fase buscamos:

- Revisar tecnologías de monitoreo de diabetes de última generación.
- Diseñar una arquitectura modular que integre dispositivos IoT, algoritmos de IA e interfaces móviles/web.
- Seleccionar herramientas y frameworks escalables y seguros.
- Entregar un prototipo funcional para la detección temprana, monitoreo continuo y alertas al paciente—centrándonos inicialmente en la retinopatía.

III. METODOLOGÍA

Se adoptó una metodología ágil basada en Scrum para guiar el desarrollo de la plataforma inteligente. Aunque algunas ceremonias se adaptaron según las restricciones del proyecto, se mantuvieron los principios clave de desarrollo iterativo, planificación por sprints y entregas continuas.

A. Marco de Desarrollo

Se implementaron las siguientes prácticas:

- Planificación y revisión de sprints: Cada sprint tenía objetivos definidos (e.g., desarrollo de módulos, integración, validación). Al final de cada sprint se realizaba una revisión para evaluar el progreso y reordenar el backlog.
- Reuniones breves semanales: Dos veces por semana se realizaban reuniones cortas para sincronizar tareas y resolver bloqueos.
- Gestión del backlog del producto: Todas las tareas—desde historias de usuario hasta pruebas y documentación—se organizaron en herramientas como Jira o Trello.
- Documentación continua: Cada módulo y capa arquitectónica fue documentado desde su implementación, incluyendo archivos README, diagramas UML, especificaciones de API y endpoints.
- Entregas incrementales: Se entregaron prototipos funcionales al final de cada sprint, incluyendo:
 - Una interfaz web con datos simulados,
 - Una API mínima para ingestión de datos de sensores,
 - Un modelo predictivo inicial integrado al sistema.

B. Arquitectura de Microservicios

La plataforma fue diseñada con una arquitectura modular dividida en:

- Capa de presentación: React Native (móvil) y Angular (web).
- Capa de integración: Apache Kafka para orquestación de servicios.
- Capa de microservicios: FastAPI para extracción de características, acceso a datos y servicios predictivos.
- Capa de procesamiento: Clústeres GPU gestionados con Kubernetes.
- Capa de acceso a datos: MongoDB (clúster replicado), respaldos en AWS S3.

C. Plan de Implementación

El desarrollo se organizó en seis fases:

1. Prototipado inicial (Meses 1–2)
 - Flujo básico frontend → backend → base de datos.
2. Integración de datos simulados (Meses 3–4)

- Lecturas simuladas de sensores IoT.
3. Módulo predictivo inicial (Meses 5–6)
 - Modelo de IA básico desplegado con TensorFlow Serving.
 4. Validación interna y optimización (Meses 7–8)
 - Simulación de eventos críticos, ajuste de umbrales.
 5. Fase piloto con datos reales (Meses 9–11)
 - Recolección de datos clínicos, reentrenamiento.
 6. Despliegue en producción (Mes 12)
 - Auditorías de seguridad, autoescalado, manuales.

D. Adquisición de Datos e Ingeniería de Características

Se utilizó el dataset IOBP2, con 440 pacientes diabéticos. De los registros brutos se generaron 13 atributos, incluyendo métricas clave de MCG. Se aplicó SMOTE para balancear clases y obtener 596 muestras por fold de validación cruzada.

E. Cronograma del Proyecto

- Mayo: Curación del dataset e ingeniería de características
- Junio: Diseño del algoritmo y entrenamiento preliminar
- Julio: Desarrollo de la app, pruebas unitarias e integración
- Agosto: Redacción del artículo, integración final y preparación de despliegue
-

IV. METODOLOGÍA DE EVALUACIÓN

Para garantizar una evaluación robusta y libre de sesgos, se siguió un proceso de evaluación en dos fases:

1. Optimización (Validación Cruzada)

- Se utilizó un conjunto de entrenamiento con 352 registros.
- Se aplicó validación cruzada de cinco pliegues para optimizar los hiperparámetros de cada algoritmo.
- Dentro de cada pliegue se aplicó SMOTE para balancear las clases (expandiéndose a 596 muestras: 298 positivas vs. 298 negativas).

2. Evaluación final (Separación Entrenamiento–Prueba)

- El mejor modelo resultante de la fase de optimización fue evaluado una sola vez sobre un conjunto de prueba aislado con 88 registros.
- Ninguno de los datos del conjunto de prueba fue visto durante el entrenamiento ni durante el ajuste de hiperparámetros.

Resultados de desempeño del modelo ganador (AdaBoost):

TABLE I. DESEMPEÑO EN VALIDACIÓN CRUZADA (CONJUNTO DE ENTRENAMIENTO)

Métrica	Valor Promedio
Recall (Sensitivity)	81.6%
Precision	30.6%
F1-Score	44.4%
AUC-ROC	80.0%

TABLE II. DESEMPEÑO FINAL (CONJUNTO DE PRUEBA)

Métrica	Valor
Recall (Sensitivity)	92.9%
Precision	34.2%
F1-Score	50.0%
AUC-ROC	78.6%
Specificity	66.2%
Overall Accuracy	70.5%

V. CASO DE ESTUDIO

Para la evaluación final del rendimiento, se compararon múltiples algoritmos de clasificación en un conjunto de prueba completamente nuevo, simulando un escenario de aplicación real. La Tabla I resume las métricas de rendimiento obtenidas para los modelos más relevantes.

TABLE III. COMPARACIÓN DE MÉTRICAS DE RENDIMIENTO EN EL CONJUNTO DE PRUEBA FINAL

Algoritmo	Recall	Precisión	F1-Score	AUC-ROC
AdaBoost	0.929	0.342	0.500	0.786
XGBoost	0.143	0.286	0.190	0.808
Random Forest	0.357	0.500	0.417	0.803
LightGBM	0.214	0.429	0.286	0.788
Regresión Logística	0.571	0.276	0.372	0.774
SVM (RBF Kernel)	0.357	0.385	0.370	0.765

El análisis comparativo revela que AdaBoost es el modelo más adecuado para el objetivo del proyecto, alcanzando un valor de Recall (Sensibilidad) de 0.929. En un contexto clínico, esta métrica es de suma importancia, ya que indica que el modelo es capaz de identificar correctamente al 92.9% de los pacientes que realmente presentan un riesgo, minimizando así la cantidad de falsos negativos. Aunque su Precisión (0.342) es modesta, su F1-Score (0.500), el más alto de la comparativa, demuestra el mejor equilibrio entre sensibilidad y precisión.

Otros modelos exhibieron fortalezas en distintas áreas. XGBoost obtuvo el mejor AUC-ROC (0.808), lo que sugiere una excelente capacidad general para discriminar entre clases. Por su parte, Random Forest alcanzó la Precisión más alta (0.500). Sin embargo, para una herramienta de prevención, la prioridad es no omitir casos de riesgo, lo que consolida a AdaBoost como la elección óptima.

Adicionalmente, se analizó la importancia de las características para el modelo AdaBoost. Los resultados revelaron que los predictores más influyentes son la Edad (importancia: 0.661), la Duración de la Diabetes (0.266) y la presencia de Hipertensión (0.072). Estas tres características concentran la totalidad del poder predictivo del modelo, subrayando la relevancia de los factores demográficos y comorbilidades en la predicción de complicaciones.

VI. CONCLUSIÓN Y TRABAJO A FUTURO

Este estudio desarrolló una plataforma inteligente para la monitorización y predicción de complicaciones en diabetes.

La evaluación final demostró que el algoritmo AdaBoost es el más efectivo para el propósito del sistema, logrando un Recall del 92.9%, lo que es fundamental para una herramienta de prevención de riesgos. El análisis también identificó la Edad, la Duración de la Diabetes y la Hipertensión como los factores predictivos más críticos. La integración de IoT, microservicios e IA facilita intervenciones oportunas y personalizadas. Como trabajo futuro, se propone ampliar la validación clínica, incorporar datos multimodales, optimizar la escalabilidad con edge computing, explorar IA explicable (XAI) e integrar blockchain para la seguridad de datos [2,4,5,6].

REFERENCIAS

- [1] Gobierno de México. (2021). *En México, 12.4 millones de personas viven con diabetes*. Secretaría de Salud.
- [2] A. Basto-Abreu, et al., "Prevalencia de prediabetes y diabetes en México: Ensanut 2022," *Salud Pública de México*, vol. 65, no. 1, pp. 1-11, 2023.
- [3] Federación Internacional de Diabetes. (2021). *Atlas de la Diabetes de la FID*.
- [4] Instituto Nacional de Estadística y Geografía. (2024). *Estadísticas a propósito del día mundial de la diabetes*.
- [5] Revista Diabetes. (2023). Aplicación de la tecnología avanzada en diabetes: Pros y contras. *Revista de la Sociedad Española de Diabetes*, vol. 14, no. 2, pp. 104-109.
- [6] A. Gudiño-Ochoa, et al., "Noninvasive diabetes detection through human breath using TinyML-powered e-nose," *Sensors*, vol. 24, no. 4, art. 1294, 2024.