

Recibido: 5 de julio del 2022 / Aceptado: 8 de octubre del 2022
doi: <https://doi.org/10.26439/interfases2022.n016.6121>

UNA REVISIÓN DE LAS IMPLEMENTACIONES DE SISTEMAS PARA LA IDENTIFICACIÓN DE TENDENCIAS DE LA DIABETES

ROCIO ISABEL BENITES LOJA
2018100484@ucss.edu.pe
<https://orcid.org/0000-0002-9671-554X>
Universidad Católica Sedes Sapientiae, Perú

MARCO ANTONIO CORAL YGNACIO
mcoral@ucss.edu.pe
<https://orcid.org/0000-0001-6628-1528>
Universidad Católica Sedes Sapientiae, Perú

RESUMEN. La diabetes *mellitus* es una enfermedad crónica que aparece cuando el páncreas no secreta suficiente insulina o cuando el organismo no utiliza apropiadamente la insulina que produce. Dado que la insulina es una hormona que regula la concentración de glucosa en la sangre, uno de los efectos más comunes de la diabetes no controlada es la hiperglucemia, que con el tiempo daña gravemente muchos órganos y sistemas del cuerpo. Por ello, es importante el desarrollo de *software* predictivo para el diagnóstico y posterior tratamiento de esta enfermedad, en particular para la diabetes tipo 1 y 2, que concentran la mayoría de los casos. El presente trabajo realiza una revisión sistemática de literatura a fin de determinar los métodos y la problemática en la construcción de sistemas de identificación de tendencias orientados a la diabetes. Los resultados muestran 16 métodos diferentes de construcción utilizados en estos sistemas, de los cuales los más eficientes son la regresión logística y las redes neuronales artificiales.

PALABRAS CLAVE: diabetes *mellitus*, identificación de tendencias, *software* preventivo, métodos de construcción, regresión logística, redes neuronales artificiales

A REVIEW OF SYSTEM IMPLEMENTATIONS FOR DIABETES TREND IDENTIFICATION

ABSTRACT. Diabetes mellitus is a chronic disease that appears when the pancreas does not secrete enough insulin or the body does not properly use the insulin it produces. Insulin is a hormone that regulates glucose concentration in the blood: one of the most common effects of uncontrolled diabetes is hyperglycemia, which seriously damages many organs and body systems over time. In this sense, the development of predictive software, the diagnosis, and subsequent treatment of diabetes, especially of type 1 and 2, which are the most frequent, deserve attention. This paper presents a systematic review of the literature to determine the methods and problems in constructing diabetes-oriented trend identification systems. The results show 16 construction methods used in these systems, the most efficient being logistic regression and artificial neural networks.

KEYWORDS: diabetes mellitus, trend identification, preventive software, construction methods, logistic regression, artificial neural networks

1. INTRODUCCIÓN

La diabetes es un trastorno metabólico considerado una enfermedad crónica o de larga duración que se caracteriza por niveles elevados de glucosa en la sangre durante un extenso periodo. Las complicaciones graves asociadas con la diabetes son, a corto plazo, la cetoacidosis diabética y, a largo plazo, complicaciones como enfermedades cardiovasculares, accidentes cerebrovasculares, insuficiencia renal crónica y otras (Jaiswal et al., 2021). Según estadísticas mundiales brindadas por la Organización Mundial de la Salud, se prevé que para el 2045 el número de pacientes con diabetes *mellitus* alcanzará los 629 millones (Felizardo et al., 2021), lo cual la convierte en un problema de salud mundial.

En este contexto, se hace necesario predecir quiénes son pacientes potenciales que podrían estar en riesgo de adquirir diabetes. Con esto se busca evitar el desarrollo de dicha enfermedad y, en caso de darse, poder aplicar el tratamiento adecuado para prevenir su progresión a gran escala (Jaiswal et al., 2021). Por ello, el sector salud promueve la implementación de sistemas de apoyo al diagnóstico y prevención de la diabetes con el objetivo de reducir sus efectos, utilizando dispositivos inteligentes y sensores (Ray & Chaudhuri, 2021) e identificación de modelos predictivos mediante métodos computacionales asociados a la inteligencia artificial (Castelyn et al., 2021b), la cual tiene el potencial de revolucionar el cuidado de la salud debido a la disponibilidad de métodos y plataformas computacionales que son cada vez más poderosas, junto con las diversas fuentes informativas de datos que se tiene de cada paciente, tanto dentro como fuera de los entornos clínicos (Gautier et al., 2021).

En el campo de la inteligencia artificial existen algoritmos de aprendizaje automático, como las redes neuronales artificiales (ANN), las máquinas de soporte vectorial (SVM), *naive Bayes* (NBC), aprendizaje profundo (DL) y técnicas de minería de datos, que se utilizan para detectar patrones y determinar el diagnóstico y tratamiento de enfermedades (Jaiswal et al., 2021). La literatura especializada muestra pocas evidencias de implementaciones de sistemas de identificación de tendencias para la diabetes; por ello, es importante investigar las diferentes formas de implementación de un sistema de detección de pacientes potenciales y predicción de glucosa en sangre para pacientes con diabetes *mellitus* tipo 1 y 2. Se propone realizar, entonces, una revisión sistemática de literatura con el fin de identificar los métodos de construcción utilizados en las implementaciones de sistemas de predicción de la diabetes a fin de dar respuestas a los objetivos planteados en esta investigación. La revisión se basa en el método de Hanna Snyder, que considera las siguientes fases: diseño de la revisión, realización de la revisión, análisis y redacción de la reseña (Snyder, 2019). Se desarrolla una estrategia de búsqueda para realizar el análisis de artículos científicos en las siguientes bases de datos, por ser de acceso

libre, por la facilidad de búsqueda y la descarga de documentos: ScienceDirect, PubMed e IEEE Xplore. Los resultados de la revisión identificaron 16 métodos diferentes de construcción, 2 métodos considerados muy eficientes y 7 problemas en la implementación de estos sistemas.

El trabajo está organizado de la siguiente manera: después de la introducción en el punto 1, el punto 2 muestra la revisión de literatura; el punto 3 describe la metodología de la revisión, seguida por la presentación de los resultados en el punto 4; el punto 5 detalla los hallazgos, y las conclusiones se encuentran en el punto 6.

2. REVISIÓN DE LITERATURA

2.1 Diabetes *mellitus*

La diabetes *mellitus* (DM) es un trastorno metabólico que resulta de un defecto en la secreción de insulina y provoca el aumento del nivel de glucosa en la sangre, lo que afecta la forma en que el cuerpo convierte los alimentos en energía. Es una enfermedad que se caracteriza por hiperglucemia crónica y se asocia con una fuerte carga en la salud microvascular (retinopatía, nefropatía y neuropatía), así como con complicaciones macrovasculares (cardiovasculares, enfermedad vascular periférica y cerebrovascular) (Peer et al., 2020).

La DM tipo 1 afecta principalmente a las células beta del páncreas, lo que lleva a una deficiencia de insulina e hiperglucemia; por ello, las personas con este tipo de diabetes dependen de la insulina, la cual debe ajustarse según los alimentos que consumen, la actividad física, el estrés y la enfermedad de por sí (Pease et al., 2019). La DM tipo 2 hace que las células del cuerpo no interactúen con la insulina o que las células pancreáticas no produzcan suficiente insulina para regular los niveles de glucosa en la sangre, lo que debilita el metabolismo de los carbohidratos, las grasas y las proteínas, dando como resultado la DM tipo 1 en caso de no haber tenido un buen control de la DM tipo 2 (Ahmed et al., 2022).

2.2 Aplicación de la inteligencia artificial en la diabetes

En la medicina, la inteligencia artificial (IA) ha hecho una gran contribución en la vida humana, gracias a la disponibilidad de diversas plataformas médicas y métodos computacionales (Gautier et al., 2021) basados en aprendizaje automático (ML) y aprendizaje profundo. La diabetes se ha convertido en una de las principales enfermedades que han sido objeto de investigaciones médicas (Kodama et al., 2022) cuya atención está puesta en el aprendizaje automático, que permite desarrollar modelos predictivos (Tuppad & Patil, 2022) y herramientas impulsadas por IA para la

detección de enfermedades (Ahmed et al., 2022) y el control de las complicaciones (De Silva, Lee et al., 2020). Una de las herramientas más utilizadas es la técnica de ML, la cual permite que los sistemas inteligentes construyan modelos apropiados mediante el aprendizaje y la extracción de patrones en los datos (Li et al., 2020), pues es necesario que un conjunto de datos apropiados tenga las características necesarias para el respectivo entrenamiento y validación (Ahmed et al., 2022). Entre las aplicaciones se encuentran sistemas para la predicción de la diabetes tipo 2, que utilizan el promedio ponderado objetivo basado en la distancia, cuyos resultados son prometedores debido a su método de predicción novedoso (Nuankaew et al., 2021). Otras aplicaciones con mejores resultados emplean más de una técnica de aprendizaje automático, integrando la lógica difusa como método de construcción (Ahmed et al., 2022).

3. METODOLOGÍA

La revisión de literatura se lleva a cabo con el propósito de investigar y sintetizar evidencia de los principales métodos que se utilizan en la construcción de sistemas de predicción para la diabetes. En el desarrollo de la investigación, se consideran las siguientes fases (Snyder, 2019): diseño de la revisión, realización de la revisión y análisis.

3.1 Diseño de la revisión

Para realizar la búsqueda de los artículos, se define el tema con la finalidad de delimitar el alcance de la investigación: sistemas de identificación de tendencias para la diabetes. Posteriormente, se determinan los siguientes objetivos en relación con las preguntas de investigación:

- P1: ¿qué métodos de construcción son utilizados para la construcción de sistemas de identificación de tendencias relacionadas con la diabetes?
O1: identificar métodos de construcción que se emplean para la construcción de sistemas de identificación de tendencias relacionadas con la diabetes.
- P2: ¿qué métodos de construcción son los más eficientes para la construcción de un sistema de identificación de tendencias para la diabetes?
O2: identificar los métodos de construcción más eficientes para la construcción de un sistema de identificación de tendencias para la diabetes.
- P3: ¿qué modelos de diagnóstico son empleados para la detección de la diabetes?
O3: identificar los modelos de diagnóstico que son empleados para la detección de la diabetes.

- P4: ¿qué problemas se han encontrado para construir un sistema de identificación de tendencias relacionadas con la diabetes?

O4: determinar cuáles han sido los problemas existentes en la construcción de sistemas de identificación de tendencias relacionadas con la diabetes.

3.2 Estrategia de búsqueda

Los criterios establecidos para la búsqueda y selección de los artículos que se tuvieron en cuenta son los que aparecen en la Tabla 1.

Tabla 1

Criterios para la búsqueda sistemática

Criterios de inclusión	Criterios de exclusión
Artículos cuyos temas de investigación están orientados a la detección de la diabetes.	Artículos que mencionen síntomas no relacionados con la diabetes.
Artículos que mencionen métodos, técnicas y/o algoritmos para la construcción de un sistema predictivo para la diabetes.	Artículos no indexados.
Artículos que guarden relación con la enfermedad de la diabetes.	Informes de casos, estudios de casos, boletines, comentarios.
Artículos publicados del 2019 hasta el 2022.	
Artículos indexados y que tengan DOI.	
Artículos escritos en inglés.	

Posteriormente se identificaron las fuentes o bases de datos bibliográficas, tales como ScienceDirect, PubMed e IEEE Xplore, para ubicar los artículos relevantes a las preguntas de investigación formuladas. Además, se determinó una selección de palabras clave, que fueron las siguientes: *models, methods, algorithms, predictions, trends, diabetes, diagnosis*, la cual sirvió para establecer la siguiente cadena de búsqueda: “diabetes” and (predictions or trends) and (Models or Methods or Algorithms) and diagnosis.

3.3 Selección de estudios

De acuerdo con los criterios definidos para la búsqueda y selección de artículos, en la primera etapa de identificación se encontraron 7329 artículos en relación con la cadena de búsqueda de las diferentes fuentes bibliográficas. En la segunda etapa

de cribado, se revisaron los artículos según los criterios de inclusión y exclusión ya señalados, y se obtuvieron 446 estudios. Finalmente, en la tercera etapa, los artículos se evaluaron y se volvieron a seleccionar de acuerdo con los criterios de elegibilidad a partir del título, las palabras clave y el resumen, considerando solo los que tengan que ver con el tema de estudio. En primera instancia, se seleccionaron 14 artículos de ScienceDirect; de PubMed se obtuvieron 150, pero se eliminaron 123 duplicados y se tienen 27 estudios; de IEEE Xplore, se obtuvieron 80 estudios, de los cuales se eliminaron 70 duplicados, por lo que quedó un total de 10 trabajos. Se concluye la selección de 50 artículos que tratan sobre la construcción de sistemas de identificación de tendencias relacionados con la diabetes.

Tabla 2

Sintaxis de selección de estudios

Base de datos bibliográfica	Etapa 1: identificación	Etapa 2: cribado	Etapa 3: elegibilidad	Artículos eliminados	Estudios seleccionados
ScienceDirect	5487	80	14	0	14
PubMed	531	249	150	123	27
IEEE Xplore	1311	117	80	70	10
Total	7329	446	244	193	50

3.4 Extracción y análisis de datos


Después de haber realizado la revisión de los 50 artículos obtenidos, se procede a realizar el análisis cuantitativo, que se presentará en diferentes gráficos estadísticos de la siguiente manera:

- Cantidad de publicaciones científicas por país
- Cantidad de artículos más citados
- Cantidad de publicaciones científicas por año de acuerdo con las bases de datos utilizadas
- Cantidad de citas por publicaciones científicas
- Cantidad de repeticiones de palabras clave

El detalle del análisis puede verse desde el siguiente enlace: https://docs.google.com/spreadsheets/d/11W78U_L0xOpYw15FeKQ3HZB5Bnl_ly2s/edit?usp=sharing&uid=114897038577244842540&rtpof=true&sd=true

Figura 1


Artículos publicados por país



En la Figura 1, se observa que la mayor parte de los estudios obtenidos provienen de tres países: Australia, India y Reino Unido, los cuales muestran un mayor interés en el tema de investigación. Igualmente, los países con un rango medio de publicaciones y también con cierto interés en la investigación son Irán, Estados Unidos, China y Alemania.

Figura 2

Los diez artículos más citados




La Figura 2 muestra que la cantidad de trabajos más referenciados y tomados en cuenta por otros autores al momento de realizar un estudio sobre sistemas de predicción de la diabetes son Vounzoulaki et al. (2020) con 95 citaciones, Woldaregay

et al. (2019) con 71 y Gandevari et al. (2019) con 61, mientras que el décimo más citado tiene 9 citaciones.

Figura 3

Artículos publicados por año



La Figura 3 muestra que, de los 50 estudios recabados, la mayor concentración de trabajos realizados fue durante el año 2021. Asimismo, se puede observar que en el año 2020 también hay predominancia de estudios publicados, mientras que en los años 2019 y 2022 las publicaciones relacionadas con el tema de investigación son menores.

Tabla 3

Palabras clave más utilizadas

Palabras clave	Frecuencia
Machine learning	19
Diabetes	9
Diabetes mellitus, systematic review	6
Meta-analysis	5
Artificial intelligence, type 1 diabetes, deep learning, prediction	4
Type 2 diabetes, diagnosis, prognosis, prediabetes	3
Disease prediction, deep neural network, data mining, hypertension, telehealth, eHealth, detection, type 2 diabetes mellitus, prediction model	2

(continúa)

(continuación)

Palabras clave	Frecuencia
Uncertainty, medical data, computational intelligence, disease diagnosis, prognostic model, digital health, gestational diabetes mellitus, telemonitoring, chronic disease, cardiovascular disease, respiratory disease, metabolic syndrome, risk, eHealth, pregnancy, digital health, diabetes technologies, diabetes management, neural networks, validation, cardiovascular risk factors, automation, algorithms, devices, hypoglycaemia, sensors, Middle-East, antidepressants use, new onset, diabetes prediction, review, electronic health records, incidences, population-based study, protocol, stroke, NHANES, feature selection, predictors, Endocrinology, metabolism, osteoporosis, pituitary, thyroid, adrenal, clinical decision support, risk assessment, chronic disease management, natural language processing, physician-patient communication, prediabetes discussions, prediabetes management, type 2, continuous glucose monitor (CGM), glucose prediction, long short term memory (LSTM), diabetic prediction, fuzzy system, fused machine learning model, diabetic symptoms, objective distance, weighting factors, information gain, diabetes mellitus prediction, adaptive synthetic sampling, benchmark, deep neural network, regression, convolutional neural networks, regression analysis, feature extraction, ensemble learning, imbalanced data, glucose management, diabetic complications, thermography, Computer Aided Design (CAD), foot ulcers, image processing, m-Health, Bolus advisors, continuous glucose monitoring, flash glucose monitoring, insulin pumps, network meta-analysis, machine learning configurations, natural language processing, systematic review screening, transfer learning, applied case study, diagnostic criteria, prevalence, TRIPOD, PROBAST, prediction models, gestational diabetes, diabetes prediction, big data, blood glucose dynamics, blood glucose level prediction, SVM, Bayesian network, apriori algorithm, back propagation algorithm, artificial neural network, medical devices, insulin, glucagon, closed-loop, hybrid, algorithm, glucose responsive, islet encapsulation, Internet of Things (IoT), healthcare-health, risk factors, diseases, obesity, overweight, Chronic Kidney Disease (CKD), pancreatic carcinoma, early diagnosis, consensus, hyperglycaemia, multimorbidity, clustering, comorbidities, complications, patterns, population health, risk stratification, data-based algorithms or models, diabetics real data, type 2 diabetes mellitus, hypoglycaemia or hypoglycemia, blood glucose level, performance measure, Scopus database, PubMed database, metabolic syndrome, prediction model	1

La Tabla 3 detalla las palabras clave más utilizadas en los artículos de investigación. Las palabras *machine learning* y *diabetes* han sido las más consideradas en los artículos con 19 y 10 repeticiones, respectivamente. Asimismo, palabras como *diabetes mellitus*, *systematic review*, *meta-analysis*, *artificial intelligence* o *prediction* fueron usadas entre 6 y 4 veces como palabras clave. El resto de palabras fueron empleadas entre 1 y 3 veces. Se observa la cantidad de temas relacionados con el tema de estudio y la conexión del *machine learning* con el tema.

4. RESULTADOS

En esta sección se da respuesta a las preguntas de investigación planteadas en el trabajo. Para ello, es necesario indicar que los métodos de construcción se refieren a los diversos métodos, técnicas o algoritmos utilizados por los diferentes autores para construir la lógica que representa un modelo computacional para predecir una enfermedad. En este sentido, algunos autores usan algoritmos haciendo referencia a la estructura procedimental que genera una lógica computacional, mientras que otros emplean técnicas más complejas o métodos estructurados en pasos o etapas.

4.1 P1: ¿qué métodos de construcción son utilizados para la construcción de sistemas de identificación de tendencias relacionadas con la diabetes?

La Tabla 5 muestra los métodos de construcción más utilizados en las implementaciones de sistemas de predicción, recabados de los artículos de investigación seleccionados.

Tabla 5

Métodos de construcción utilizados en las implementaciones de sistemas de predicción

Referencia	Método de construcción	Descripción
(Schwartz et al., 2022), (De Silva, Jönsson & Demmer, 2020), (De Silva et al., 2021), (Zhu et al., 2021), (Zaitcev et al., 2020), (Tuppada & Patil, 2022), (Fregoso-Aparicio et al., 2021), (Kodama et al., 2022), (Zhang et al., 2022), (Fitriyani et al., 2019), (Hong et al., 2020)	Regresión logística	Es un modelo estadístico que se utiliza para determinar la probabilidad de que ocurra un evento. Además, es considerado uno de los algoritmos de <i>machine learning</i> más simples y más utilizados para tareas de clasificación.
(Ahmed et al., 2022), (Zaitcev et al., 2020), (Khan et al., 2021), (De Silva, Lee et al., 2020), (Jaiswal et al., 2021), (Woldaregay et al., 2019), (Chaki et al., 2020), (Fitriyani et al., 2019), (Shahid & Singh, 2019), (Safaei et al., 2021)	Redes neuronales artificiales (ANN) o perceptrón multicapa	Una red neuronal es un método de la inteligencia artificial que enseña a las computadoras a procesar datos en la forma en que lo hace el cerebro humano; para este caso, está expresado en el conocimiento de un experto.
(Schwartz et al., 2022), (Zhu et al., 2021), (Zaitcev et al., 2020), (Li et al., 2020), (Felizardo et al., 2021)	Redes neuronales convolucionales (CNN)	Son un tipo de redes neuronales artificiales muy efectivas para tareas de visión artificial, como la clasificación y segmentación de imágenes, entre otras aplicaciones.
(Nuankaew et al., 2021)	Distancia objetiva ponderada promedio (AWOD)	Es un método de aplicación a los datos mediante un promedio ponderado.

(continúa)

(continuación)

(Q. Wang et al., 2019)	Algoritmo CART, algoritmo DMP_MI	CART es un algoritmo de clasificación y árboles de regresión ampliamente utilizado en análisis predictivo.
(Jaiswal et al., 2021), (Woldaregay et al., 2019), (Nuankaew et al., 2021), (Zimmerman et al., 2021), (Hong et al., 2020)	<i>Support vector machine</i> (SVM)	Es un modelo de aprendizaje automático supervisado que utiliza algoritmos de clasificación para problemas de clasificación.
(Q. Wang et al., 2019), (Tuppap & Patil, 2022)	<i>Naive Bayes</i> (NB)	Es un modelo de predicción basado en la probabilidad bayesiana, considerada también como un algoritmo clasificador.
(Fitriyani et al., 2019), (Tuppap & Patil, 2022)	Árboles de decisión	Es un modelo de predicción cuyos posibles resultados se obtienen de una serie de decisiones relacionadas.
(Nuankaew et al., 2021)	Vecinos más cercanos (KNN)	Es un método de clasificación que, a pesar de su simplicidad, puede superar a los clasificadores más potentes.
(Q. Wang et al., 2019)	Muestreo sintético adaptativo (ADASYN)	Es un método de sobremuestreo que realiza una especie de balanceo en datos.
(Castelyn et al., 2021a)	Algoritmo heurístico basado en umbrales	Es un algoritmo basado reglas que, a partir de un conocimiento previo, indica qué acción tomar.
(Xie & Wang, 2020)	Método recursivo o directo	Es un método empleado cuando se sabe cómo resolver de manera directa un problema para un cierto conjunto de datos.
(Schwartz et al., 2022)	Sistema basado en reglas	Es un conjunto de reglas que representa de forma natural el conocimiento explícito de los expertos.
(Shahid & Singh, 2019)	AB (AdaBoost), algoritmo evolutivo	AdaBoost es un método basado en reglas, mientras que el algoritmo evolutivo es un método de optimización y búsqueda de soluciones basado en la evolución biológica.
(Vounzoulaki et al., 2020)	Estadísticos: Begg y Egger	Son pruebas estadísticas de estimaciones.
(Schwartz et al., 2022)	Programación neurolingüística (PNL)	Es un campo de la inteligencia artificial que investiga la manera de comunicar las máquinas con las personas.

4.2 P2: ¿qué métodos de construcción son los más eficientes para la construcción de un sistema de identificación de tendencias para la diabetes?

La Tabla 6 muestra el análisis realizado a partir de los resultados y conclusiones de cada trabajo. Se omiten aquellos donde los autores no indican de forma expresa los resultados o los niveles de eficiencia obtenidos con el método de construcción utilizado.

Tabla 6

Métodos más eficientes en la construcción de sistemas de predicción

Método de construcción	Resultados obtenidos de los métodos	Eficiencia
Regresión logística	Se obtuvo un alto rendimiento para predicciones (De Silva, Jönsson & Demmer, 2020); es un método que puede aplicarse dependiendo de las necesidades del sistema por implementar (Schwartz et al., 2022).	Muy eficiente
Redes neuronales artificiales	Se obtuvo un mayor rendimiento en comparación con otros métodos de pruebas, lo que ha generado grandes posibilidades en el reconocimiento de patrones de enfermedades (Safaei et al., 2021).	Muy eficiente
Distancia objetiva ponderada promedio (AWOD)	El método basado en AWOD proporcionó una precisión del 93,22 % y del 98,95 % para el conjunto de datos 1 y el conjunto de datos 2, respectivamente (Nuankaew et al., 2021).	Eficiente
DMP_MI	El algoritmo DMP_MI propuesto ha superado a otros algoritmos en precisión con un 87,10 % y otros indicadores de rendimiento del clasificador, con lo que ha demostrado un gran potencial para la predicción de la diabetes (Q. Wang et al., 2019).	Eficiente
Begg y Egger	Los resultados obtenidos indican que las pruebas de Begg y Egger no fueron estadísticamente significativas (Vounzoulaki et al., 2020).	Poco eficiente

4.3 P3: ¿qué modelos de diagnóstico son empleados para la detección de la diabetes?

La Tabla 7 muestra los modelos de diagnóstico computacionales y no computacionales empleados para la detección de enfermedades como la diabetes. Entre los computacionales están los modelos predictivos construidos mediante las técnicas de inteligencia artificial. Sin embargo, se encontraron también encuestas y criterios

de diagnóstico considerados modelos no computacionales para su aplicación en sistemas de predicción.

Tabla 7

Modelos de diagnóstico para la detección de la diabetes

Referencia	Modelos de diagnóstico
(Gautier et al., 2021)	Encuestas autoinformadas.
(Gautier et al., 2021), (Jaiswal et al., 2021), (Shahid & Singh, 2019), (Felizardo et al., 2021), (Hong et al., 2020), (Schwartz et al., 2022), (Zhang et al., n.d.2022), (Kodama et al., 2022), (Fregoso-Aparicio et al., 2021), (Tuppad & Patil, 2022), (Nuankaew et al., 2021), (Xie & Wang, 2020)	Modelos predictivos construidos mediante técnicas de inteligencia artificial como ANN, RL, <i>naive Bayes</i> , árboles de decisión, SVM, entre otros.
(Y. Wang et al., 2021), (Safaei et al., 2021), (Galbete et al., 2022)	Uso de criterios de diagnóstico de diabetes, como sexo, edad, consumo de alcohol, depresión, obesidad, IMC, hipertensión, etcétera.
(Madhava & Verma, 2019)	Termografía mediante el sistema detección asistido por ordenador (CAD).

4.4 P4: ¿qué problemas se han encontrado para construir un sistema de identificación de tendencias relacionadas con la diabetes?

La Tabla 8 muestra el análisis realizado a los resultados y conclusiones de cada trabajo estudiado; se rescatan solo aquellos donde se expresan de forma puntual problemas relacionados con la implementación y construcción de sistemas de predicción sobre la diabetes.

Tabla 8

Problemas en la construcción de sistemas de predicción relacionados con la diabetes

Referencia	Problemática
(Safaei et al., 2021)	Se menciona como problema que la implementación de un sistema de predicción basado en redes neuronales artificiales solo se puede aplicar para un conjunto de parámetros conocidos, es decir, las variables de entrada.
(De Silva et al., 2021)	Se evidencia cierto grado de comparabilidad en los resultados al emplear solo tres algoritmos de desempeño, pero existen ciertas diferencias identificadas que son notables. Debido a esto, se recalca la importancia de aplicar una variedad de algoritmos para obtener mejores resultados.
(Jaiswal et al., 2021)	Se menciona como problema que, si no se fusiona un conjunto de datos para lograr una mejor precisión, no se tendrá un modelo confiable.

(continúa)

(continuación)

(Schwartz et al., 2022)	Se menciona como problema que un sistema simple basado en reglas es inadecuado para identificar discusiones de prediabetes debido a la poca especificidad.
(Q. Wang et al., 2019)	Se menciona como problema que, debido a la falta de sensibilidad de la precisión para los datos desequilibrados, se consideran indicadores integrales para la evaluación del desempeño, como la precisión, la recuperación, la puntuación F1 y el área bajo la curva (AUC).
(Gautier et al., 2021)	Pocos estudios investigan problemas de una población en particular; los estudios se reducen a hospitales o clínicas, por lo que la calidad y la suficiencia de los datos es un obstáculo para el modelo que se va a utilizar.
(Asgari et al., 2021)	Se evidenció que el modelo desarrollado no aumentó la capacidad en el tamizaje/predicción de la DM tipo 2, principalmente en la parte de análisis, debido a la falta de validación externa de los modelos de predicción.

5. HALLAZGOS

Los resultados obtenidos a partir de los estudios seleccionados mencionan que los métodos de construcción más eficientes son la regresión logística, considerada un método sólido como otros algoritmos de clasificación, y las redes neuronales, que también se ajustan a sistemas de predicción, pero es necesario iterar varias veces en el entrenamiento para que el modelo o la arquitectura de red propuesta busque minimizar los errores y los resultados sean muy próximos a los del experto humano. Además, se halla que los modelos de diagnóstico más utilizados por la medicina son los computacionales, mediante los diversos modelos predictivos que provee la inteligencia artificial.

Los resultados obtenidos confirman que la inteligencia artificial es la base de nuevas herramientas que ayudan a diagnosticar y prevenir diversas enfermedades.

6. CONCLUSIONES

Los métodos de construcción utilizados en implementaciones de sistemas de predicción relacionados con la diabetes se basan en técnicas y algoritmos de inteligencia artificial en su mayoría, aunque también se utilizan las pruebas estadísticas para este fin.

Se concluye que la complejidad de cada método depende de los datos que sean manejados para inferir la solución. Generalmente, los modelos de aprendizaje automático dependen de las características del conjunto de datos que se tiene como entrada.

De acuerdo con el análisis realizado, se puede determinar que la regresión logística y las redes neuronales artificiales son los métodos de construcción que mejores resultados han mostrado en las predicciones realizadas.

También es posible afirmar que existen modelos no computacionales que pueden ser utilizados en la detección y diagnóstico de la diabetes, los cuales han presentado buenos resultados. Respecto a los problemas, se concluye que la mayoría se centra en los datos que usarán los modelos de predicción, siendo la calidad y la confiabilidad los factores más importantes en este aspecto.

REFERENCIAS

- Ahmed, U., Issa, G. F., Khan, M. A., Aftab, S., Khan, M. F., & Said, R. A. T. (2022). Prediction of diabetes empowered with fused machine learning. *IEEE Access*, 10, 8529-8538. <https://doi.org/10.1109/ACCESS.2022.3142097>
- Asgari, S., Khalili, D., & Hosseinpanah, F. (2021). Prediction models for type 2 diabetes risk in the general population: A systematic review of observational studies. *International Journal of Endocrinology and Metabolism*, 19(3). <https://doi.org/10.5812/ijem.109206.Systematic>
- Barbaresko, J., Neuenschwander, M., Schwingshackl, L., & Schlesinger, S. (2019). Dietary factors and diabetes-related health outcomes in patients with type 2 diabetes: Protocol for a systematic review and meta-analysis of prospective observational studies. *BMJ Open*, 9(7). <https://doi.org/10.1136/bmjopen-2018-027298>
- Castelyn, G., Laranjo, L., Schreier, G., & Gallego, B. (2021a). Predictive performance and impact of algorithms in remote monitoring of chronic conditions: A systematic review and meta-analysis. *International Journal of Medical Informatics*, 156, 104620. <https://doi.org/10.1016/j.ijmedinf.2021.104620>
- Castelyn, G., Laranjo, L., Schreier, G., & Gallego, B. (2021b). Predictive performance and impact of algorithms in remote monitoring of chronic conditions: A systematic review and meta-analysis. *International Journal of Medical Informatics*, 156, 104620. <https://doi.org/10.1016/j.ijmedinf.2021.104620>
- Chaki, J., Thillai Ganesh, S., Cidham, S. K., & Ananda Theertan, S. (2020). Machine learning and artificial intelligence based diabetes mellitus detection and self-management: A systematic review. *Journal of King Saud University - Computer and Information Sciences*, 34, 3204-3225. <https://doi.org/10.1016/j.jksuci.2020.06.013>

- Cicek, M., Buckley, J., Pearson-Stuttard, J., & Gregg, E. W. (2021). Characterizing multimorbidity from type 2 diabetes: Insights from clustering approaches. *Endocrinology and Metabolism Clinics of North America*, 50(3), 531-558. <https://doi.org/10.1016/j.ecl.2021.05.012>
- De Silva, K., Jönsson, D., & Demmer, R. T. (2020). A combined strategy of feature selection and machine learning to identify predictors of prediabetes. *Journal of the American Medical Informatics Association*, 27(3), 396-406. <https://doi.org/10.1093/jamia/ocz204>
- De Silva, K., Lee, W. K., Forbes, A., Demmer, R. T., Barton, C., & Enticott, J. (2020). Use and performance of machine learning models for type 2 diabetes prediction in community settings: A systematic review and meta-analysis. *International Journal of Medical Informatics*, 143, 104268. <https://doi.org/10.1016/j.ijmedinf.2020.104268>
- De Silva, K., Lim, S., Mousa, A., Teede, H., Forbes, A., Demmer, R. T., Jönsson, D., & Enticott, J. (2021). Nutritional markers of undiagnosed type 2 diabetes in adults: Findings of a machine learning analysis with external validation and benchmarking. *PLOS ONE*, 16(5), e0250832. <https://doi.org/10.1371/journal.pone.0250832>
- Diouri, O., Cigler, M., Vettoretti, M., Mader, J. K., Choudhary, P., & Renard, E. (2021). Hypoglycaemia detection and prediction techniques: A systematic review on the latest developments. *Diabetes/Metabolism Research and Reviews*, 37(7), e3449. <https://doi.org/10.1002/dmrr.3449>
- Domingo-Lopez, D. A., Lattanzi, G., H. J. Schreiber, L., Wallace, E. J., Wylie, R., O'Sullivan, J., Dolan, E. B., & Duffy, G. P. (2022). Medical devices, smart drug delivery, wearables and technology for the treatment of diabetes mellitus. *Advanced Drug Delivery Reviews*, 185, 114280. <https://doi.org/10.1016/j.addr.2022.114280>
- Eberle, C., Loehnert, M., & Stichling, S. (2021). Clinical effectiveness of different technologies for diabetes in pregnancy: Systematic literature review. *Journal of Medical Internet Research*, 23(4). <https://doi.org/10.2196/24982>
- Farmanfarma, K. H. K., Zareban, I., & Adineh, H. A. (2020). Prevalence of type 2 diabetes in Middle-East: Systematic review & meta-analysis. *Primary Care Diabetes*, 14(4), 297-304. <https://doi.org/10.1016/j.pcd.2020.01.003>
- Felizardo, V., Garcia, N. M., Pombo, N., & Megdiche, I. (2021). Data-based algorithms and models using diabetics real data for blood glucose and hypoglycaemia

- prediction – A systematic literature review. *Artificial Intelligence in Medicine*, 118, 102120. <https://doi.org/10.1016/j.artmed.2021.102120>
- Fitriyani, N. L., Syafrudin, M., Alfian, G., & Rhee, J. (2019). Development of disease prediction model based on ensemble learning approach for diabetes and hypertension. *IEEE Access*, 7, 144777-144789. <https://doi.org/10.1109/ACCESS.2019.2945129>
- Fregoso-Aparicio, L. F., Noguez, J., Montesinos, L., & García, J. A. G. (2021). Machine learning and deep learning predictive models for type 2 diabetes: A systematic review. *Diabetology & Metabolic Syndrome*, 13. <https://doi.org/10.1186/s13098-021-00767-9>
- Galbete, A., Tamayo, I., Libroero, J., Enguita-Germán, M., Cambra, K., & Ibáñez-Beroiz, B. (2022). Cardiovascular risk in patients with type 2 diabetes: A systematic review of prediction models. *Diabetes Research and Clinical Practice*, 184. <https://doi.org/10.1016/j.diabres.2021.109089>
- Gandevani, S. B., Amiri, M., Yarandi, R. B., & Tehrani, F. R. (2019). The impact of diagnostic criteria for gestational diabetes on its prevalence: A systematic review and meta-analysis. *Diabetology & Metabolic Syndrome*, 11, 1-18. <https://doi.org/10.1186/s13098-019-0406-1>
- Gautier, T., Ziegler, L. B., Gerber, M. S., Campos-Náñez, E., & Patek, S. D. (2021). Artificial intelligence and diabetes technology: A review. *Metabolism: Clinical and Experimental*, 124. <https://doi.org/10.1016/j.metabol.2021.154872>
- Haghi Kashani, M., Madanipour, M., Nikravan, M., Asghari, P., & Mahdipour, E. (2021). A systematic review of IoT in healthcare: Applications, techniques, and trends. *Journal of Network and Computer Applications*, 192, 103164. <https://doi.org/10.1016/j.jnca.2021.103164>
- Hong, N., Park, H., & Rhee, Y. (2020). Machine learning applications in endocrinology and metabolism research: An overview. *Endocrinology and Metabolism*, 35(1), 71-84. <https://doi.org/10.3803/EnM.2020.35.1.71>
- Jaiswal, V., Negi, A., & Pal, T. (2021). A review on current advances in machine learning based diabetes prediction. *Primary Care Diabetes*, 15(3), 435-443. <https://doi.org/10.1016/j.pcd.2021.02.005>
- Kattini, R., Hummelen, R., & Kelly, L. (2020). Early gestational diabetes mellitus screening with glycated hemoglobin: A systematic review. *Journal of Obstetrics and Gynaecology Canada*, 42(11), 1379-1384. <https://doi.org/10.1016/j.jogc.2019.12.015>

- Khan, F. A., Zeb, K., Al-Rakhami, M., Derhab, A., & Bukhari, S. A. C. (2021). Detection and prediction of diabetes using data mining: A comprehensive review. *IEEE Access*, 9, 43711-43735. <https://doi.org/10.1109/ACCESS.2021.3059343>
- Kodama, S., Fujihara, K., Horikawa, C., Kitazawa, M., Iwanaga, M., Kato, K., Watanabe, K., Nakagawa, Y., Matsuzaka, T., Shimano, H., & Sone, H. (2022). Predictive ability of current machine learning algorithms for type 2 diabetes mellitus: A meta-analysis. *Journal of Diabetes Investigation*, 13(5), 900-908. <https://doi.org/10.1111/jdi.13736>
- Kvitkina, T., Narres, M., Claessen, H., Metzendorf, M. I., Richter, B., & Icks, A. (2020). Incidence of stroke in the diabetic compared with the non-diabetic population: A systematic review protocol. *Diabetes/Metabolism Research and Reviews*, 36(6). <https://doi.org/10.1002/dmrr.3311>
- Li, K., Daniels, J., Liu, C., Herrero, P., & Georgiou, P. (2020). Convolutional recurrent neural networks for glucose prediction. *IEEE Journal of Biomedical and Health Informatics*, 24(2), 603-613. <https://doi.org/10.1109/JBHI.2019.2908488>
- Madhava, P. S., & Verma, S. (2019). A systematic literature review for early detection of type ii diabetes. En *2019 5th International Conference on Advanced Computing and Communication Systems (ICACCS)* (pp. 220-224). <https://doi.org/10.1109/ICACCS.2019.8728377>
- Magliano, D. J., Islam, R. M., Barr, E. L. M., Gregg, E. W., Pavkov, M. E., Harding, J. L., Tabesh, M., Koye, D. N., & Shaw, J. E. (2019). Trends in incidence of total or type 2 diabetes: Systematic review. *BMJ*, 366. <https://doi.org/10.1136/bmj.l5003>
- Nuankaew, P., Chaising, S., & Temdee, P. (2021). Average weighted objective distance-based method for type 2 diabetes prediction. *IEEE Access*, 9, 137015-137028. <https://doi.org/10.1109/ACCESS.2021.3117269>
- Pease, A., Lo, C., Earnest, A., Kiriakova, V., Liew, D., & Zoungas, S. (2019). The efficacy of technology in type 1 diabetes: A systematic review, network meta-analysis, and narrative synthesis. *Diabetes Technology & Therapeutics*, 22(5), 411-421. <https://doi.org/10.1089/dia.2019.0417>
- Peer, N., Balakrishna, Y., & Durao, S. (2020). Screening for type 2 diabetes mellitus. *Cochrane Database of Systematic Reviews*, 5. <https://doi.org/10.1002/14651858.CD005266.pub2>
- Ray, A., & Chaudhuri, A. K. (2021). Smart healthcare disease diagnosis and patient management: Innovation, improvement and skill development. *Machine Learning with Applications*, 3, 100011. <https://doi.org/10.1016/j.mlwa.2020.100011>

- Safaei, M., Sundararajan, E. A., Driss, M., Boulila, W., & Shapi'i, A. (2021). A systematic literature review on obesity: Understanding the causes & consequences of obesity and reviewing various machine learning approaches used to predict obesity. *Computers in Biology and Medicine*, 136, 104754. <https://doi.org/10.1016/j.combiomed.2021.104754>
- Santos, D. S., Regina, C., Batistelli, S., & Marilac, M. (2022). The effectiveness of the use of telehealth programs in the care of individuals with hypertension and, or diabetes mellitus: Systematic review and meta-analysis. *Diabetology & Metabolic Syndrome*, 14, 76. <https://doi.org/10.1186/s13098-022-00846-5>
- Schwartz, J. L., Tseng, E., Maruthur, N. M., & Rouhizadeh, M. (2022). Identification of prediabetes discussions in unstructured clinical documentation: Validation of a natural language processing algorithm. *Journal of Medical Internet Research*, 10(2). <https://doi.org/10.2196/29803>
- Shahid, A. H., & Singh, M. P. (2019). Computational intelligence techniques for medical diagnosis and prognosis: Problems and current developments. *Biocybernetics and Biomedical Engineering*, 39(3), 638-672. <https://doi.org/10.1016/j.bbe.2019.05.010>
- Snyder, H. (2019). Literature review as a research methodology: An overview and guidelines. *Journal of Business Research*, 104, 333-339. <https://doi.org/10.1016/j.jbusres.2019.07.039>
- Tuppad, A., & Patil, S. D. (2022). Machine learning for diabetes clinical decision support: A review. *Advances in Computational Intelligence*, 2(2), 1-24. <https://doi.org/10.1007/s43674-022-00034-y>
- Vounzoulaki, E., Khunti, K., Abner, S. C., Tan, B. K., Davies, M. J., & Gillies, C. L. (2020). Progression to type 2 diabetes in women with a known history of gestational diabetes: Systematic review and meta-analysis. *BMJ*, 369, m1361. <https://doi.org/10.1136/bmj.m1361>
- Wang, Q., Cao, W., Guo, J., Ren, J., Cheng, Y., & Davis, D. N. (2019). DMP_MI: An effective diabetes mellitus classification algorithm on imbalanced data with missing values. *IEEE Access*, 7, 102232-102238. <https://doi.org/10.1109/ACCESS.2019.2929866>
- Wang, Y., Liu, D., Li, X., Liu, Y., & Wu, Y. (2021). Antidepressants use and the risk of type 2 diabetes mellitus: A systematic review and meta-analysis. *Journal of Affective Disorders*, 287(45), 41-53. <https://doi.org/10.1016/j.jad.2021.03.023>
- Woldaregay, A. Z., Årsand, E., Walderhaug, S., Albers, D., Mamykina, L., Botsis, T., & Hartvigsen, G. (2019). Data-driven modeling and prediction of blood

- glucose dynamics: Machine learning applications in type 1 diabetes. *Artificial Intelligence in Medicine*, 98, 109-134. <https://doi.org/10.1016/j.artmed.2019.07.007>
- Xie, J., & Wang, Q. (2020). Benchmarking machine learning algorithms on blood glucose prediction for type i diabetes in comparison with classical time-series models. *IEEE Transactions on Biomedical Engineering*, 67(11), 3101-3124. <https://doi.org/10.1109/TBME.2020.2975959>
- Zaitcev, A., Eissa, M. R., Hui, Z., Good, T., Elliott, J., & Benaissa, M. (2020). A deep neural network application for improved prediction of HbA 1c in type 1 diabetes. *IEEE Journal of Biomedical and Health Informatics*, 24(10), 2932-2941. <https://doi.org/10.1109/JBHI.2020.2967546>
- Zhang, H., Shao, J., Chen, D., Zou, P., Ciu, N., Tang, L., Wang, D., & Ye, Z. (2020). Reporting and methods in developing prognostic prediction models for metabolic syndrome: A systematic review and critical appraisal. *Diabetes, Metabolic Syndrome and Obesity*, 13, 4981-4992.
- Zhang, Z., Yang, L., Han, W., Wu, Y., Zhang, L., Gao, C., Jiang, K., Liu, Y., & Wu, H. (2022). Machine learning prediction models for gestational diabetes mellitus: Meta-analysis. *Journal of Medical Internet Research*, 24(3). <https://doi.org/10.2196/26634>
- Zheng, M., Bernardo, C. O., Stocks, N., & Gonzalez-Chica, D. (2022). Diabetes mellitus diagnosis and screening in Australian general practice: A national study. *Journal of Diabetes Research*. DOI: 10.1155/2022/156640
- Zhu, T., Li, K., Herrero, P., & Georgiou, P. (2021). Deep learning for diabetes: A systematic review. *IEEE Journal of Biomedical and Health Informatics*, 25(7), 2744-2757. <https://doi.org/10.1109/JBHI.2020.3040225>
- Zimmerman, J., Soler, R. E., Lavinder, J., Murphy, S., Atkins, C., Hulbert, L., Lusk, R., & Ng, B. P. (2021). Iterative guided machine learning-assisted systematic literature reviews: A diabetes case study. *Systematic Reviews*, 10, 97. <https://doi.org/10.1186/s13643-021-01640-6>