

## Artigo de revisão

### Inteligência artificial no manejo do diabetes mellitus: revisão integrativa da literatura

*Artificial intelligence in the management of diabetes mellitus: an integrative literature review*

Daniella Antunes Pereira Rocha<sup>1</sup>  | Aline Teixeira<sup>1</sup>  | Ana Clara Lacerda Freitas<sup>1</sup>  | Isis Gabriella Antunes Lopes Veloso<sup>1</sup>  | Árlen Almeida Duarte de Sousa<sup>1,2,3</sup>  | Andréa Maria Eleutério de Barros Lima Martins<sup>1,2</sup> 

<sup>1</sup>Centro Universitário do Norte de Minas (Uninorte), Montes Claros, MG, Brasil. [ROR: <https://ror.org/05t3h0r03>]

<sup>2</sup>Programa de Pós-graduação em Ciências da Saúde da Universidade Estadual de Montes Claros (Unimontes), Montes Claros, MG, Brasil. [ROR: <https://ror.org/01hewbk46>]

<sup>3</sup>Centro de Excelência de Pesquisa em Saúde (CEPS) da Universidade Estadual de Montes Claros (Unimontes), Montes Claros, MG, Brasil. [ROR: <https://ror.org/01hewbk46>]

## Resumo

**Objetivo:** analisar as aplicações da inteligência artificial no manejo do diabetes mellitus. **Materiais e Métodos:** revisão integrativa da literatura realizada a partir da análise de artigos publicados entre 2020 e 2025. Após aplicação dos critérios de inclusão e exclusão, foram selecionados 14 artigos originais. A análise considerou os princípios metodológicos do modelo PICO e as diretrizes PRISMA (*Preferred Reporting Items for Systematic reviews and Meta-Analyses*). **Resultados:** os estudos evidenciaram que modelos de aprendizado de máquina apresentaram elevado potencial para predição de complicações, estratificação de risco, otimização do monitoramento glicêmico e apoio à tomada de decisão clínica. Sistemas computacionais de triagem, algoritmos preditivos, dispositivos vestíveis e chatbots demonstraram utilidade na personalização do cuidado e na promoção do letramento em saúde. **Conclusão:** a inteligência artificial pode ser uma estratégia promissora para o manejo do diabetes mellitus ao ampliar a precisão diagnóstica, favorecer intervenções precoces e aprimorar o acompanhamento clínico, embora desafios relacionados à padronização dos dados, validação científica, aceitabilidade profissional e integração tecnológica ainda são observados.

**Palavras-chave:** Inteligência artificial. Diabetes mellitus. Controle glicêmico. Literacia para a Saúde.

## Abstract

**Objective:** to analyze studies addressing the application of artificial intelligence in the management of diabetes mellitus, identifying the main tools employed. **Materials and Methods:** integrative literature review conducted in indexed databases, including articles published between 2020 and 2025. After applying inclusion and exclusion criteria, 14 original studies were selected. The analysis followed the methodological principles of the PICO model and the PRISMA guidelines (*Preferred Reporting Items for Systematic reviews and Meta-Analyses*). **Results:** the studies showed that machine learning models present high potential for predicting complications, stratifying clinical risk, optimizing glycemic monitoring and supporting clinical decision making. Computational triage systems, predictive algorithms, wearable devices and chatbots demonstrated usefulness in care personalization and in promoting health literacy. **Conclusion:** artificial intelligence represents a promising strategy for the management of diabetes mellitus by improving diagnostic accuracy, enabling earlier interventions and enhancing clinical follow up, although challenges related to data standardization, scientific validation, professional acceptance and technological integration still require overcoming to consolidate its safe and effective use in healthcare practice.

**Keywords:** Artificial Intelligence. Diabetes Mellitus. Glycemic control. Health Literacy.

Autor correspondente: Daniella Antunes Pereira Rocha | [daniella.rocha@soufunorte.com.br](mailto:daniella.rocha@soufunorte.com.br)

Recebido em: 27|11|2025. Aprovado em: 25|05|2026.

Avaliado pelo processo de *double blind review*.

Como citar este artigo: Rocha DAP, Teixeira A, Freitas ACL, Veloso IGAL, , Sousa AAD, Martin AMEBL. Inteligência artificial no manejo do diabetes mellitus: revisão integrativa da literatura. Bionorte. 2026;15:eXXXX. <https://doi.org/10.47822/bn.v15i1.1271>



## Introdução

O diabetes mellitus (DM) é uma condição metabólica crônica caracterizada por níveis persistentemente elevados de glicose no sangue. Decorre de uma produção insuficiente de insulina pelo pâncreas ou em função da incapacidade do organismo de utilizá-la de maneira eficiente<sup>1</sup>. É dividido em quatro categorias principais: tipo 1 (DM1), tipo 2 (DM2), gestacional (DMG) e outros tipos de diabetes. O mais comum é o DM2, responsável por cerca de 90% dos casos que ocorre quando o corpo não utiliza de forma eficiente a insulina produzida, chamado de resistência à insulina, ou não gera uma quantidade suficiente para manter os níveis de glicose no sangue controlados<sup>2</sup>.

Entre os homens, as faixas de 55 a 64 anos e 65 a 74 anos apresentaram as maiores prevalências. Entre as mulheres, o padrão é semelhante, com prevalências mais elevadas nas mesmas faixas etárias. Estimativas indicam que, até 2045, mais de 700 milhões de pessoas poderão ser afetadas pelo DM, o que evidencia a necessidade de implementação de estratégias eficazes para sua prevenção e manejo<sup>3</sup>. Apesar dos avanços na área da saúde, sua detecção precoce ainda representa um desafio, pois, em muitos casos, o diagnóstico ocorre tardiamente, quando as complicações já estão estabelecidas. Essa situação evidencia o impacto da falta de informação sobre o DM, um fator que contribui para a busca tardia por cuidados médicos e o consequente agravamento do quadro clínico dos pacientes<sup>4</sup>.

Nesse cenário, a inteligência artificial (IA) surge como uma ferramenta em potencial para análise de grandes volumes de dados clínicos, identificar padrões e correlações que podem prever o desenvolvimento da doença. A aplicação de técnicas avançadas de IA, como aprendizado de máquina, tem demonstrado grande potencial na predição e diagnóstico do diabetes<sup>5</sup>. Permite que sistemas aprendam com dados e realizem previsões sem a necessidade de programação específica. Para seu funcionamento eficaz e ético, são fundamentais três princípios: integridade, precisão e conformidade<sup>6</sup>. Além das aplicações clínicas, a IA se destaca como uma ferramenta de letramento em saúde (LS), uma vez que pode auxiliar pacientes na gestão do diabetes em seu cotidiano<sup>5</sup>.

Objetivou-se analisar a aplicação da inteligência artificial no manejo do diabetes mellitus a partir de um estudo revisional.

## Materiais e Métodos

Trata-se de uma revisão integrativa da literatura, que consistiu na busca e avaliação criteriosa de estudos publicados. Esse estudo permite reunir e analisar minuciosamente resultados de pesquisas originais para oferecer uma síntese analítica sobre determinado tema. Optou-se pelo espaço temporal dos últimos cinco anos devido à crescente utilização da IA nos contextos da saúde neste período,

principalmente após o lançamento da ferramenta “ChatGPT” em 2022 pela “OpenAI”.

A problemática foi formulada com base no modelo PICO (*Patient/Population, Intervention, Control e Outcome*), estratégia metodológica amplamente utilizada na formulação de perguntas norteadoras<sup>7</sup> (Quadro 1). Desta forma, formulou-se a seguinte pergunta norteadora: Como as metodologias de aplicação da inteligência artificial contribuem para o manejo do diabetes mellitus?

**Quadro 1.** Descrição da ferramenta PICO (*Patient/Population, Intervention, Control e Outcome*).

	<b>Descrição</b>	<b>Definição nessa Revisão Integrativa</b>
P	<i>Population</i>	Pacientes diagnosticados com Diabetes Mellitus
I	<i>Intervention</i>	Utilização da Inteligência Artificial para monitoramento, diagnóstico e tratamento
C	<i>Control</i>	Métodos tradicionais de diagnóstico, controle e tratamento
O	<i>Outcome</i>	Maior precisão e eficácia no diagnóstico precoce, melhoria no controle glicêmico, redução de complicações e otimização da administração de insulina

Fonte: Adaptado de Pereira<sup>7</sup>.

A busca foi realizada nas bases de dados Latino Americana e do Caribe em Ciências da Saúde (LILACS), *National Library of Medicine* (PubMed) e *Scientific Electronic Library Online* (SciELO), utilizando os seguintes descritores indexados nos Descritores em Ciências da Saúde: a) “diabetes mellitus” AND “inteligência artificial”; b) “diabetes mellitus” AND “aprendizado de máquina”; c) “diabetes mellitus” AND “*artificial intelligence*”; d) “diabetes mellitus” AND “*machine learning*”. O Quadro 2 mostra os distintos filtros aplicados para garantir a seleção de artigos originais nas três bases de dados.

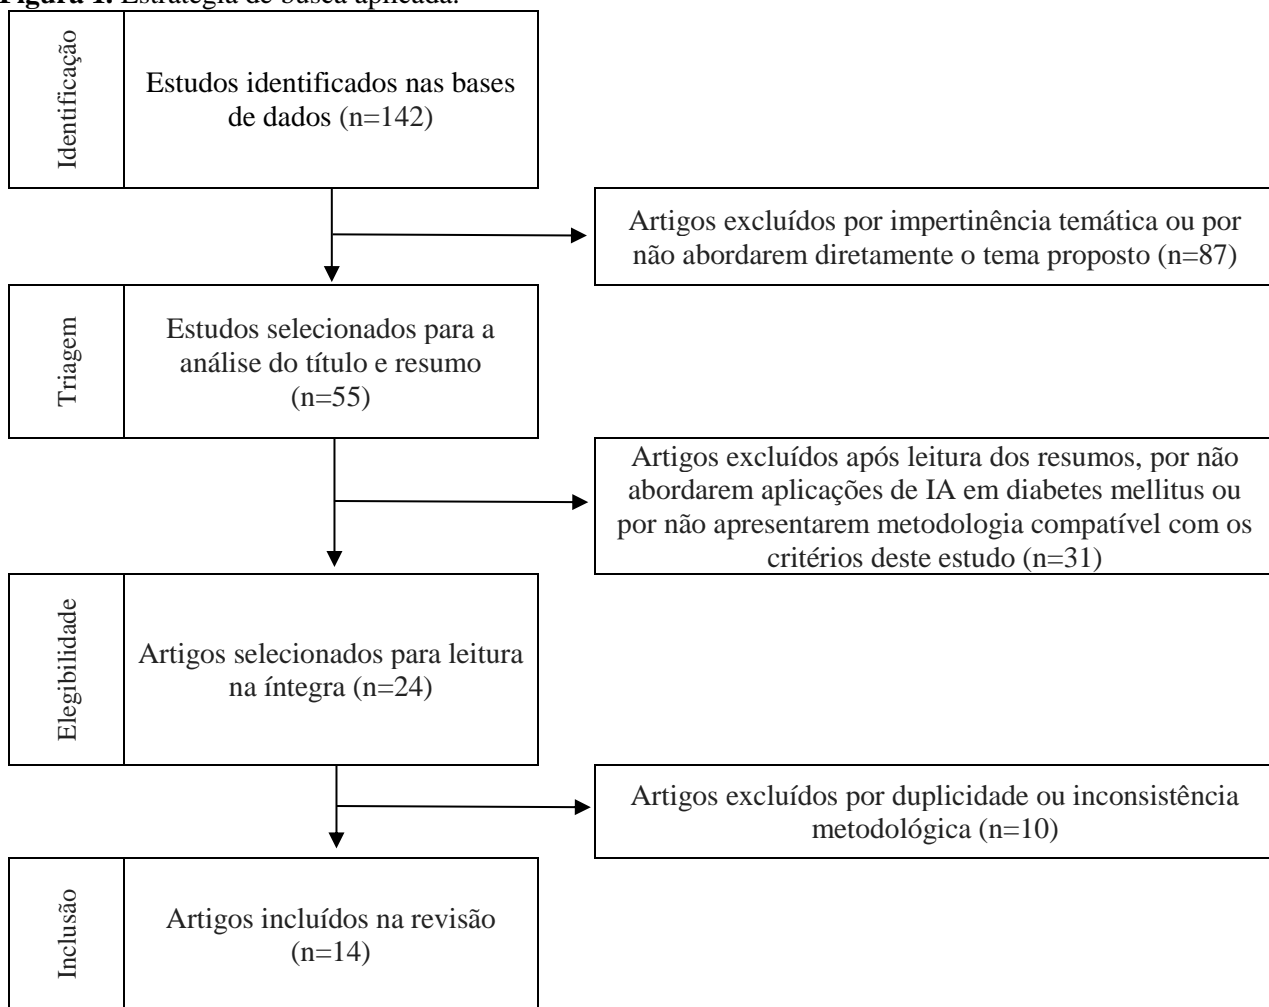
**Quadro 2.** Filtros de busca dos artigos aplicados nas buscas.

	<b>Latino Americana e do Caribe em Ciências da Saúde</b>	<b>PubMed</b>	<b>Scientific Electronic Library Online</b>
Descrição dos filtros	Estudos diagnósticos, observacionais, de prevalência, de fatores de risco, de rastreamento e de etiologia	Ensaio clínico adaptativos, estudo clínico, ensaio clínico, estudo observacional, estudo comparativo, ensaio clínico randomizado, estudo de validação e estudo de avaliação.	Artigos; Experimental; Medicine; Research.

Foram incluídos estudos originais que abordassem aplicações da IA e do aprendizado de máquina no manejo do DM, e artigos com metodologias alinhadas à proposta do presente estudo e

conduzidos com rigor científico, contendo dados quantitativos ou qualitativos relevantes para a temática. Também foram incluídas publicações entre 2020 e 2025 disponíveis nos idiomas português, inglês ou espanhol. Foram excluídos artigos de revisão, meta-análises ou diretrizes clínicas, estudos sem metodologia definida e duplicados.

**Figura 1.** Estratégia de busca aplicada.



As divergências entre os pesquisadores foram solucionadas por meio da técnica do consenso, seguindo os princípios do modelo PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*)<sup>8</sup>, que estabelece diretrizes para a condução transparente e rigorosa de revisões sistemáticas e integrativas.

Foi utilizado um formulário de coleta de dados para análise crítica dos estudos, composto pelas informações: título; autores; ano; local de execução do estudo; amostra; objetivo; delineamento e principais resultados. A metodologia adotada permitiu consolidar informações relevantes sobre as aplicações e desafios da IA no manejo do DM, fornecendo uma base sólida para a análise dos resultados.

## Resultados

Foram incluídos 14 estudos publicados entre 2021 e 2024. Observou-se predominância de delineamentos retrospectivos<sup>10,14,17,19,20</sup> e observacionais<sup>9,15,20</sup>, além de um ensaio clínico<sup>11</sup> e outros tipos de estudos<sup>5,12,16,18,22</sup>. As investigações contemplaram estudos realizados em diferentes continentes, com diversidade metodológica quanto ao tamanho amostral, aos algoritmos empregados e aos desfechos analisados (Quadro 3).

As aplicações da inteligência artificial no manejo do DM concentraram-se em quatro eixos principais: a) predição glicêmica e monitoramento metabólico; b) predição de risco e complicações; c) triagem de retinopatia diabética; e d) comparação de métodos diagnósticos e algoritmos.

Em intervenções digitais aplicadas ao monitoramento metabólico<sup>9,10,20</sup>, observou-se redução da hemoglobina glicada e maior proporção de pacientes atingindo metas glicêmicas. Nos estudos voltados à predição de risco e complicações<sup>11,13,15,17,19,21</sup>, os modelos de aprendizado de máquina apresentaram desempenho elevado, com alta capacidade discriminativa e boa acurácia na identificação de desfechos clínicos.

Na triagem de retinopatia diabética<sup>14,16,18,22</sup>, os sistemas baseados em IA demonstraram sensibilidade entre 90,48% e 98,52% e especificidade superior a 85%, evidenciando boa acurácia diagnóstica. Nos estudos de comparação de métodos diagnósticos e algoritmos<sup>5,12</sup>, verificou-se forte correlação entre métodos baseados em IA e exames laboratoriais tradicionais, ainda que com variações pontuais nos valores estimados, além da superioridade de determinados algoritmos quanto à acurácia e precisão preditiva.

Os resultados indicam que a IA possui potencial para melhorar o controle do DM pelo aprimoramento da prevenção, diagnóstico e tratamento. Sua aplicação pode contribuir para a personalização do cuidado, a antecipação de riscos clínicos e a otimização de condutas terapêuticas.

**Quadro 3.** Características dos estudos selecionados. (n=14).

Autor, ano	País e ano da investigação	Objetivo	Metodologia	Principais resultados
Doorn <i>et al.</i> , 2021 <sup>9</sup>	Países Baixos, 2016–2018	Predizer níveis glicêmicos por meio da Inteligência Artificial, utilizando dados de monitoramento contínuo da glicose e atividade física.	Estudo observacional com 851 indivíduos. Utilizou modelo <i>Long Short-Term Memory</i> . Validação realizada com base de dados de diabetes mellitus tipo 1.	Erro Quadrático Médio ( <i>Root Mean Square Error</i> [RMSE]) variando entre 0,37 e 0,59 mmol/L. Previsões consideradas seguras em mais de 98% dos casos.
Oliveira; Barcelos; Siqueira, 2022 <sup>12</sup>	Brasil, 2021	Correlacionar a dosagem de glicose obtida por glicosímetro, análise laboratorial e sistema baseado em inteligência artificial.	Estudo transversal com 20 voluntários, realizado por meio de coletas simultâneas.	Forte correlação entre os métodos ( $r > 0,75$ ). O sistema baseado em inteligência artificial superestimou os valores glicêmicos em aproximadamente 40%.

Du <i>et al.</i> , 2022 <sup>11</sup>	China, 2018–2020	Avaliar a ressonância magnética funcional associada à inteligência artificial, por meio do algoritmo <i>Fuzzy C-Means</i> no cuidado domiciliar da nefropatia diabética.	Ensaio clínico com 64 pacientes.	Efetividade de 96,9%, melhor cobertura e satisfação.
Kim <i>et al.</i> , 2022 <sup>10</sup>	Coreia do Sul, 2019	Analisar padrões de estilo de vida por meio da inteligência artificial associada a rastreadores corporais.	Estudo prospectivo com 24 adultos, utilizando dispositivos Fitbit, técnica SHAP ( <i>SHapley Additive exPlanations</i> ) e métodos de agrupamento de dados.	Redução de 0,3% nos níveis de hemoglobina glicada (HbA1c) associada à regularidade do sono.
Lee <i>et al.</i> , 2022 <sup>13</sup>	Coreia do Sul, 2015–2020	Predizer Diabetes Mellitus gestacional por meio da Inteligência Artificial e de variáveis associadas à Doença Hepática Gordurosa Não Alcoólica.	Estudo de coorte com 1.443 gestantes, utilizando modelos de aprendizado de máquina, incluindo regressão logística, <i>Random Forest</i> , <i>Support Vector Machine</i> e <i>Deep Neural Network</i> .	Área sob a curva ( <i>Area Under the Curve</i> [AUC]) de até 0,819 no modelo <i>Support Vector Machine</i> . A inclusão de variáveis relacionadas à Doença Hepática Gordurosa Não Alcoólica melhorou a capacidade preditiva dos modelos.
Acharyya <i>et al.</i> , 2023 <sup>14</sup>	Índia, 2019–2020	Avaliar o sistema de inteligência artificial Adven-i na triagem de retinopatia diabética e outras doenças da retina.	Estudo retrospectivo com análise de 2.261 imagens.	Sensibilidade de 95,12% e especificidade superior a 85%.
Kwiendacz <i>et al.</i> , 2023 <sup>15</sup>	Polônia, 2021–2022	Predizer o risco cardiovascular em pacientes com diabetes mellitus por meio da inteligência artificial.	Estudo observacional com 238 pacientes.	Área sob a curva ( <i>Area Under the Curve</i> [AUC]) de 0,86. Os principais preditores identificados foram idade, uso de $\beta$ -bloqueadores, inibidores da enzima conversora de angiotensina (IECA) e presença de úlceras.
Lupidi <i>et al.</i> , 2023 <sup>16</sup>	Itália, 2022	Validar o sistema de inteligência artificial Selena+ na triagem de retinopatia diabética.	Estudo transversal com 251 pacientes.	Sensibilidade e especificidade de 96,8%.
Wang <i>et al.</i> , 2023 <sup>17</sup>	Estados Unidos, 2007–2018	Predizer insuficiência cardíaca em pacientes com diabetes mellitus e pré-diabetes por meio de modelos de inteligência artificial.	Estudo retrospectivo com 3.527 indivíduos, utilizando cinco algoritmos de aprendizado de máquina.	O algoritmo <i>Random Forest</i> apresentou área sob a curva ( <i>Area Under the Curve</i> [AUC]) de 0,978. As principais variáveis preditoras foram idade, presença de dor e uso de medicamentos antidiabéticos.
Zhang <i>et al.</i> , 2024 <sup>19</sup>	China, 2019–2023	Detectar diabetes mellitus e pré-diabetes em indivíduos normoglicêmicos por meio de modelos de inteligência artificial.	Estudo retrospectivo com 59.259 indivíduos, utilizando sete algoritmos de aprendizado de máquina.	O modelo CatBoost apresentou área sob a curva ( <i>Area Under the Receiver Operating Characteristic</i> [auROC]) de 0,806 na validação interna e 0,794 na validação externa.

Shamanna <i>et al.</i> , 2024 <sup>20</sup>	Índia, 2022–2023	Avaliar intervenção com gêmeo digital em Diabetes Mellitus tipo 2.	Estudo observacional retrospectivo com 1.853 pacientes.	Redução da hemoglobina glicada (HbA1c) de 8,1% para 6,3%, com 89% dos pacientes atingindo a meta glicêmica. Observou-se também perda média de 4,8 kg e redução no uso de medicamentos.
Fregoso-Aparicio <i>et al.</i> , 2021 <sup>5</sup>	México, 2021	Comparar modelos de aprendizado de máquina e aprendizado profundo para predição do diabetes tipo 2 e identificar técnicas associadas ao melhor desempenho preditivo.	Revisão sistemática da literatura conduzida conforme as recomendações PRISMA, com análise comparativa de modelos de aprendizado de máquina e aprendizado profundo aplicados à predição do diabetes tipo 2.	Algoritmos baseados em árvores apresentaram melhor desempenho preditivo para diabetes tipo 2. Técnicas de balanceamento de dados e seleção de características aumentaram a eficiência dos modelos, enquanto redes neurais profundas apresentaram desempenho inferior ao esperado. Modelos treinados em conjuntos de dados organizados alcançaram resultados próximos da perfeição.
Cleland <i>et al.</i> , 2024 <sup>22</sup>	Tanzânia, 2023–2024	Avaliar o impacto da Inteligência Artificial na adesão ao acompanhamento oftalmológico após triagem de retinopatia diabética.	Ensaio com 2.364 pacientes, utilizando o sistema de Inteligência Artificial Selenia+.	Estudo em andamento com avaliação da adesão ao acompanhamento e da custo-efetividade da intervenção.
Doğan <i>et al.</i> , 2024 <sup>18</sup>	Turquia, 2023	Comparar o desempenho de câmeras não-miátricas associadas ao sistema de inteligência artificial <i>EyeCheckup</i> .	Estudo clínico com 865 pacientes, baseado na análise de imagens.	Sensibilidade entre 90,48% e 98,52% e especificidade entre 95,93% e 98,95%.

## Discussão

A utilização de modelos preditivos baseados em aprendizado de máquina constitui uma das principais frentes de inovação nas aplicações da IA no diagnóstico e tratamento do DM. Estudos demonstraram o potencial desses modelos para prever níveis glicêmicos com alta precisão<sup>9,10</sup>. Há evidências de que algoritmos baseados em redes neurais recorrentes foram capazes de prever a glicemia com alto grau de acurácia, a partir de dados de monitoramento contínuo de glicose, e configuram ferramenta promissora para sistemas automatizados de administração de insulina<sup>10</sup>.

O uso de dispositivos vestíveis, aliados a algoritmos de aprendizado de máquina, permitiu a identificação de padrões de estilo de vida mais saudáveis em pessoas com DM2, com impacto direto na redução da hemoglobina glicada<sup>10</sup>. Esses achados reforçam o potencial da IA para personalização do cuidado e otimização do controle glicêmico, especialmente pela integração de dados contínuos e comportamentais à tomada de decisão clínica.

Em estudo voltado ao acompanhamento de pacientes com nefropatia diabética, foram empregados algoritmos de visão computacional para análise de imagens por ressonância magnética funcional, e a combinação da IA com o modelo de cuidado *Plan-Do-Check-Act* (PDCA), em português, Planejar-Fazer-Verificar-Agir, resultou em melhora da qualidade de vida e maior efetividade clínica<sup>11</sup>. No contexto diagnóstico, verificou-se forte correlação entre três métodos de dosagem de glicose (glicosímetro, laboratório e equipamento *point-of-care* com IA), embora os valores obtidos pelo sistema com IA tenham sido, em média, 40% mais elevados, o que pode impactar a interpretação clínica dos exames<sup>12</sup>. Esse resultado evidencia que, apesar da elevada correlação entre os métodos, ainda existem limitações relacionadas à padronização e calibração dos sistemas baseados em IA, aspecto essencial para sua incorporação segura à prática clínica.

Investigação desenvolveu modelos preditivos para diabetes gestacional com base em variáveis clínicas associadas à Doença Hepática Gordurosa Não Alcoólica, com uso de diferentes algoritmos de IA, entre eles a Máquina de Vetores de Suporte. A inclusão dessas variáveis elevou a acurácia preditiva, especialmente nos modelos baseados em máquina de vetores de suporte e redes neurais artificiais<sup>13</sup>. Foi avaliado um sistema de IA (Adven-i) para triagem de retinopatia diabética e outras doenças da retina, com sensibilidade superior a 91% e especificidade superior a 85%, o que demonstra potencial para aplicações em larga escala<sup>14</sup>. No mesmo contexto, técnicas de regressão e agrupamento foram utilizadas para prever o risco cardiovascular em pessoas que vivem com diabetes, com Área sob a Curva (AUC) de 0,86 e identificação de preditores-chave, como idade, uso de  $\beta$ -bloqueadores e presença de úlcera no pé<sup>15</sup>. Esses resultados demonstram a capacidade dos modelos de IA em reconhecer padrões complexos e variáveis clínicas associadas à ocorrência de complicações.

O algoritmo de IA Selen+ para triagem de retinopatia diabética com câmeras não midriáticas foi validado e apresentou sensibilidade e especificidade de 96,8%, além de elevada concordância com especialistas ( $\kappa=0,935$ )<sup>16</sup>. Modelos preditivos também foram aplicados para detectar risco de insuficiência cardíaca em pacientes com pré-diabetes e DM, e o algoritmo *Random Forest* apresentou AUC de 0,978, superior às abordagens tradicionais<sup>17</sup>. Em estudo que comparou o desempenho de três câmeras oftalmológicas não midriáticas associadas ao sistema *EyeCheckup*, observaram-se valores de sensibilidade entre 90,48% e 98,52% e especificidade superior a 95%, ressaltando a importância da padronização das imagens para garantir a acurácia diagnóstica da IA<sup>18</sup>. Esses achados sugerem que a qualidade das imagens e a escolha adequada dos algoritmos podem influenciar o desempenho diagnóstico dos sistemas inteligentes.

Em análise comparativa de diferentes algoritmos de aprendizado de máquina aplicados ao banco de dados de mulheres indígenas Pima, verificou-se que o modelo de Floresta Aleatória apresentou maior precisão para a predição de DM, sugerindo viabilidade diagnóstica em populações

específicas<sup>5</sup>. Em estudo baseado em ampla base de dados chinesa, foram treinados algoritmos capazes de identificar casos de pré-diabetes e DM em indivíduos com glicemia normal, e o modelo CatBoost apresentou desempenho superior, com área sob a curva (auROC) de até 0,806, reforçando o papel da IA na detecção precoce da doença<sup>19</sup>. Em investigação voltada à personalização do cuidado em DM2, evidenciou-se que a IA pode identificar padrões comportamentais e promover melhor adesão ao tratamento<sup>20</sup>. De modo complementar, foram desenvolvidos e validados externamente algoritmos preditivos não laboratoriais para triagem de DM, com boa sensibilidade e especificidade<sup>21</sup>. Em conjunto, esses estudos indicam que a IA pode ampliar a capacidade diagnóstica e favorecer abordagens preventivas mais individualizadas.

A aplicação da IA em triagens oftalmológicas para retinopatia diabética pode aumentar a adesão dos pacientes ao atendimento especializado<sup>22</sup>. A integração desses sistemas aos prontuários eletrônicos e às práticas clínicas requer diretrizes robustas de regulamentação, capacitação profissional e infraestrutura tecnológica. Apesar dos desafios relacionados à variabilidade dos dados clínicos e à alfabetização digital dos pacientes, os estudos incluídos nesta revisão<sup>5,9-22</sup> apontam impacto positivo da IA na melhoria do cuidado em DM, desde o rastreamento precoce até a personalização terapêutica.

Como limitações desta revisão integrativa, destaca-se a restrição temporal dos estudos incluídos, a heterogeneidade metodológica quanto ao tamanho amostral, aos algoritmos empregados e às métricas de desempenho utilizadas, o que pode dificultar a comparabilidade direta entre os resultados.

## Conclusão

A IA pode contribuir para o tratamento do DM por meio da aprendizagem de máquinas para predição de complicações, *chatbots* para educação em saúde e monitoramento contínuo da glicemia. Os estudos analisados demonstraram a crescente aplicação da IA no controle dessa condição, como detecção precoce, personalização do tratamento e suporte à decisão clínica.

## Contribuições dos autores

**Concepção e desenho da pesquisa:** Daniella Antunes Pereira Rocha, Aline Teixeira, Ana Clara Lacerda Freitas. **Análise, interpretação dos dados e redação do manuscrito:** Daniella Antunes Pereira Rocha, Aline Teixeira, Ana Clara Lacerda Freitas. **Administração dos recursos:** Daniella Antunes Pereira Rocha, Aline Teixeira, Ana Clara Lacerda Freitas. **Revisão crítica do manuscrito quanto ao conteúdo intelectual e apresentação final:** Isis Gabriella Antunes Lopes Veloso, Árlen Almeida Duarte de Sousa, Andréa Maria Eleutério de Barros Lima Martin. Os autores aprovaram a versão final do manuscrito e se declararam responsáveis por todos os aspectos do trabalho, incluindo a garantia de sua precisão e integridade.

## Conflito de interesses

Os autores declararam não haver conflitos de interesse.

## Agradecimentos

À Universidade Estadual de Montes Claros (Unimontes), Minas Gerais, Brasil e ao Centro Universitário do Norte de Minas (Uninorte), Montes Claros, Minas Gerais, Brasil.

## Financiamento

À Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG, Processo: APQ-03038-21), Minas Gerais, Brasil. O Prof. Dr. Árlen Almeida Duarte de Sousa é bolsista BIPDT da FAPEMIG (Bolsa de Incentivo à Pesquisa e ao Desenvolvimento Tecnológico, processo: FCT-00328-25).

## Referências

1. Goyal R, Singhal M, Jialal I. Type 2 Diabetes. 2023 Jun 23. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing; 2026 Jan. <https://pubmed.ncbi.nlm.nih.gov/30020625/>
2. Sociedade Brasileira de Diabetes. Classificação do Diabetes Mellitus. Diretrizes SBD 2021-2022 [Internet]. São Paulo: SBD; 2021 [citado em 26 fev. 2025] Available from: <https://www.diabetes.org.br>.
3. Sociedade Brasileira de Diabetes. Dados epidemiológicos do Diabetes Mellitus no Brasil. Relatório SBD [Internet]. São Paulo: SBD; 2024 [acessado em 2025 maio 05]. Available from: <https://www.diabetes.org.br>.
4. Young KG, McGovern AP, Barroso I, Hattersley AT, Jones AG, Shields BM, et al. The impact of population-level HbA1c screening on reducing diabetes diagnostic delay in middle-aged adults: a UK Biobank analysis. *Diabetologia*. 2023;66(2):300-309. <https://doi.org/10.1007/s00125-022-05824-0>
5. Fregoso-Aparicio L, Noguez J, Montesinos L, García-García JA. Machine learning and deep learning predictive models for type 2 diabetes: a systematic review. *Diabetol Metab Syndr*. 2021;13:148. <https://doi.org/10.1186/s13098-021-00767-9>
6. Branco S, Teffé CS. Inteligência artificial e Big Data: diálogos da pós-graduação em Direito Digital. Rio de Janeiro: Instituto de Tecnologia e Sociedade do Rio de Janeiro; 2022.
7. Pereira MG. Artigos científicos: como redigir, publicar e avaliar. 6ª ed. Rio de Janeiro: Guanabara Koogan; 2013.
8. Moher D, Liberati A, Tetzlaff J, Altman DG. Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. *PLoS Med*. 2009;6(7):e1000097. <https://doi.org/10.1371/journal.pmed.1000097>
9. Doorn WPTM, Foreman YD, Schaper NC, Savelberg HHCM, Koster A, van der Kallen CJH, et al. Machine learning-based glucose prediction with use of continuous glucose and physical activity monitoring data: The Maastricht Study. *PLoS One*. 2021;16(6):e0253125. <https://doi.org/10.1371/journal.pone.0253125>
10. Kim KJ, Lee JB, Choi J, Seo JY, Yeom JW, Cho CH, et al. Identification of healthy and unhealthy lifestyles by a wearable activity tracker in type 2 diabetes: a machine learning-based analysis. *Endocrinol Metab (Seoul)*, 2022;37(4):547-51. <https://doi.org/10.3803/enm.2022.1479>
11. Du Q, Liang D, Zhang L, Chen G, Li X. Evaluation of functional magnetic resonance imaging under artificial intelligence algorithm on Plan-Do-Check-Action home nursing for patients with diabetic nephropathy. *Contrast Media Mol Imaging*. 2022;2022:9882532. <https://doi.org/10.1155/2022/9882532>

12. Oliveira GG, Barcelos RP, Siqueira LO. Analysis of correlation of glucose dosage by glycosimeter, laboratory dosage and artificial intelligence equipment. *J Bras Patol Med Lab.* 2022;58(1):1-6. <https://doi.org/10.1900/JBPML.2022.58.414>.
13. Lee SM, Hwangbo S, Norwitz ER, Koo JN, Oh IH, Choi ES, *et al.* Nonalcoholic fatty liver disease and early prediction of gestational diabetes mellitus using machine learning methods. *Clin Mol Hepatol.* 2022;28(1):105-16. <https://doi.org/10.3350/cmh.2021.0174>
14. Acharyya M, Moharana B, Jain S, Tandon M. A double-blinded study for quantifiable assessment of the diagnostic accuracy of AI tool “ADVEN-I” in identifying diseased fundus images including diabetic retinopathy on a retrospective data. *Indian J Ophthalmol.* 2023;72(Suppl 1):S46-52. [https://doi.org/10.4103/IJO.IJO\\_3342\\_22](https://doi.org/10.4103/IJO.IJO_3342_22)
15. Kwiendacz H, Wijata AM, Nalepa J, Piaśnik J, Kulpa J, Herba M, *et al.* Machine learning profiles of cardiovascular risk in patients with diabetes mellitus: the Silesia Diabetes-Heart Project. *Cardiovasc Diabetol.* 2023;22:221. <https://doi.org/10.1186/s12933-023-01938-w>.
16. Lupidi M, Danieli L, Fruttini D, Nicolai M, Lassandro N, Chhablani J, Mariotti C. Artificial intelligence in diabetic retinopathy screening: clinical assessment using handheld fundus camera in a real-life setting. *Acta Diabetol.* 2023;60(7):1083-8. <https://doi.org/10.1007/s00592-023-02104-0>
17. Wang Y, Hou R, Ni B, Jiang Y, Zhang Y. Development and validation of a prediction model based on machine learning algorithms for predicting the risk of heart failure in middle-aged and older US people with prediabetes or diabetes. *Clin Cardiol.* 2023;46(10):1234-43. <https://doi.org/10.1002/clc.24104>
18. Doğan ME, Bilgin AB, Sari R, Bulut M, Akar Y, Aydemir M. Head-to-head comparison of diagnostic performance of three non-mydratric cameras for diabetic retinopathy screening with artificial intelligence. *Eye (Lond).* 2024;38:1694-1701. <https://doi.org/10.1038/s41433-024-03000-9>
19. Zhang X, Yao W, Wang D, Hu W, Zhang G, Zhang Y. Development and validation of machine learning models for identifying prediabetes and diabetes in normoglycemia. *Diabetes Metab.* 2024;50(2):101489. <https://doi.org/10.1002/dmrr.70003>
20. Shamanna P, Erukulapati RS, Shukla A, Shah L, Willis B, Thajudeen M, *et al.* One-year outcomes of a digital twin intervention for type 2 diabetes: a retrospective real-world study. *Sci Rep.* 2024;14:25478. <https://doi.org/10.1038/s41598-024-76584-7>
21. Cheng WHG, Dong W, Tse ETY, Bedford LE, Fong DYT, Wong CKH, *et al.* External validation of the Hong Kong Chinese non-laboratory risk models and scoring algorithm for case finding of prediabetes and diabetes mellitus in primary care. *J Diabetes Investig.* 2024;15(6):1317-25. <https://doi.org/10.1111/jdi.14256>
22. Cleland CR, Bascaran C, Makupa W, Shilio B, Sandi FA, Philippin H, *et al.* Artificial intelligence-supported diabetic retinopathy screening in Tanzania: rationale and design of a randomised controlled trial. *BMJ Open.* 2024;14:e075055. <https://doi.org/10.1136/bmjopen-2023-075055>