

# XXIX ENFERMAIO E VI SIEPS

Inteligência artificial, Enfermagem e saúde:  
aplicabilidades, impactos e perspectivas futuras

REALIZAÇÃO



APOIO



## INTELIGÊNCIA ARTIFICIAL NO MONITORAMENTO CONTÍNUO DE GLICOSE EM PESSOAS COM DIABETES TIPO 1: REVISÃO SISTEMÁTICA

Amanda Caboclo Flor<sup>1</sup>

Kellen Alves Freire<sup>2</sup>

Sarah Ellen da Paz Fabricio<sup>3</sup>

Samuel Miranda Mattos<sup>4</sup>

Virna Ribeiro Feitosa Cestari<sup>5</sup>

Thereza Maria Magalhães Moreira<sup>6</sup>

TRABALHO PARA PRÊMIO: PÓS-GRADUAÇÃO - EIXO 1: ENFERMAGEM EM SAÚDE DO ADULTO E DO IDOSO

### RESUMO

O diabetes mellitus tipo 1 (DM1) é uma doença autoimune caracterizada pela destruição das células beta pancreáticas, resultando em alterações nos níveis de glicose. Como a variabilidade glicêmica está associada a desfechos desfavoráveis, o uso de tecnologias baseadas em inteligência artificial (IA) e modelos preditivos tem se mostrado promissor para o manejo glicêmico. Este estudo teve como objetivo avaliar os efeitos da IA associada aos sistemas de monitorização contínua da glicose (CGM) em desfechos glicêmicos em indivíduos com DM1. Trata-se de uma revisão sistemática conduzida em março de 2026. As buscas foram realizadas nas bases PubMed/MEDLINE, Scopus, Web of Science e Embase. O risco de viés foi avaliado pelas ferramentas PROBAST e ROBINS-I. Não foi realizada meta-análise, sendo adotada síntese narrativa. Após triagem, 11 estudos foram incluídos. Os estudos, conduzidos em países de alto desenvolvimento, utilizaram técnicas de machine learning e deep learning, demonstrando efeitos positivos na redução dos níveis glicêmicos e na predição de eventos glicêmicos. Conclui-se que a integração entre IA e CGM representa avanço relevante no manejo do DM1, com impacto direto no controle glicêmico.

**Palavras-chave:** Inteligência artificial; Diabetes mellitus tipo 1; Monitorização contínua da glicose.

1. Mestre em Cuidados Clínicos em Enfermagem e Saúde. Universidade Estadual do Ceará (UECE)

2. Mestre em Cuidados Clínicos em Enfermagem e Saúde. Universidade Estadual do Ceará (UECE)

3. Mestre em Saúde Coletiva. Universidade Estadual do Ceará (UECE).

4. Doutor em Cuidados Clínicos em Enfermagem e Saúde. Universidade Estadual do Ceará (UECE)

5. Doutora em Enfermagem. Universidade Estadual do Ceará (UECE)

6. Pós-Doutora em Enfermagem. Universidade Estadual do Ceará (UECE)

E-mail do autor: caboclo.flor@uece.br

## INTRODUÇÃO

O diabetes mellitus tipo 1 (DM1) pode ser definido como um distúrbio de caráter autoimune decorrente de uma deficiência grave de insulina devido a destruição das células  $\beta$ . Sua apresentação clínica pode vir associada a um diagnóstico abrupto, levando a necessidade de insulino-terapia plena desde o diagnóstico ou após um curto período de descoberta da condição, além de flutuações contínuas nos níveis de glicose, devido a ajustes de insulina de via exógena (SBD, 2025).

O mecanismo de atuação de doença crônica pode levar a desfechos clínicos desfavoráveis quando se mantém uma hiperglicemia ou oscilações em níveis de glicose de forma sustentada (LI *et al.*, 2021). Diante disso, a utilização de tecnologias para a gestão do autocuidado, que auxiliam no manejo dos níveis glicêmicos, se faz relevante quando se aborda os controles de níveis glicêmicos. Nesse contexto, os sistemas de monitorização contínua da glicose (CGM), são uma ferramenta útil para pacientes com DM1, pois podem auxiliar na predição de riscos e no entendimento sobre a individualidade de cada paciente (Vettoretti *et al.*, 2020).

O avanço das tecnologias que utilizam a inteligência artificial (IA), tem ampliado o alcance das capacidades dos CGM, ajudando a normalização dos parâmetros glicêmicos. Ressalta-se ainda lacunas na literatura acerca dos potenciais efeitos a curto e longo prazo no DM1, decorrentes de vulnerabilidades socioeconômicas, que limitam o acesso à saúde, principalmente em países subdesenvolvidos. Assim, esta revisão tem por objetivo avaliar os efeitos do uso de IA, associada aos sistemas de monitorização contínua da glicose (CGM), sobre desfechos glicêmicos, em indivíduos com DM1.

## MÉTODO

Trata-se de uma revisão sistemática de literatura, conduzida conforme as recomendações do *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA) (Page *et al.*, 2021) e o protocolo foi registrado na plataforma PROSPERO (*International Prospective Register of Systematic Reviews*) (CENTRE FOR REVIEWS AND DISSEMINATION, 2024).

Para nortear a busca, utilizou-se a seguinte pergunta: “Quais os efeitos do uso de IA, associada a CGM sobre desfechos glicêmicos em indivíduos com diabetes mellitus?”, baseado na estratégia *Population, Intervention, Comparison e Outcomes* (PICO), na qual a (P) correspondeu a pessoas adultas com diabetes mellitus tipo 1, (I) a tecnologias de inteligência artificial e modelos preditivos para monitoramento de níveis de glicose, (C) monitorização glicêmica tradicional comparado ao uso de CGM com IA e (O) incluíram desfechos em valores de glicemia.

Foram incluídos estudos primários de pessoas com DM, independentemente do tipo e tempo de diagnóstico, que avaliassem a comparação de interesse, sem restrição de idioma, nos últimos cinco anos. A revisão também contou com estudos que utilizaram técnicas de IA e/ou modelos preditivos, incluindo algoritmos de aprendizado de máquina, aprendizado profundo, bem como modelos estatísticos e calculadoras preditivas aplicadas aos dados de CGM em indivíduos com DM1.

A restrição temporal justifica-se pelo estudo considerar os avanços da última década dos CGM, a evolução da IA e dos modelos de predição de risco. Com a popularização de dispositivos que utilizam o recurso da IA para o cuidado diário com o DM, a revisão buscou por estudos com desfechos que refletissem a contemporaneidade, com as tecnologias mais utilizadas pela sociedade atual. Já a escolha pelo público adulto se justifica por especificidades no público pediátrico e idoso no que diz respeito à autocuidado e cogestão, que possam ter influência no desfecho observado.

A organização da equação de busca levou em consideração as recomendações do COSMIN (Terwee *et al.*, 2009). Em adição, houve a utilização de ferramentas gratuitas de IA para a junção de descritores ideais para cada base de dados, garantindo um maior acesso à literatura científica sobre o assunto de interesse na revisão. Portanto, os estudos potencialmente relevantes foram recuperados a partir de equação de busca, constituída por vocabulários controlados do Descritores em Ciências da Saúde (DeCS), *Medical Subject Headings* (MeSH) e Emtree, sendo realizada em março de 2026, nas bases de dados MEDLINE/PubMed, Scopus, *Web of Science* e Embase, adaptando a estratégia de busca para cada base de dados.

Foram utilizados descritores e termos livres combinados por operadores booleanos, incluindo: “Diabetes Mellitus tipo 1” e “*type 1 diabetes*”, “*Continuous Glucose Monitoring*”, “*continuous glucose monitoring*”, “*flash glucose monitoring*”, “*continuous glucose monitor*”, “*Artificial Intelligence*”, “*Machine Learning*”, “*Deep Learning*”, “*artificial intelligence*”, “*machine learning*”, “*deep learning*”, “*neural network\**”, “*algorithm\**”, “*predictive model*”, “*glycemic control*”, “*HbA1c*” e “*time in range*”, separados pelos booleanos “AND” e “OR”.

Os estudos identificados foram exportados para o Rayyan<sup>®</sup>, com a seleção realizada em três etapas com dois revisores independentes, com eventuais dúvidas com um terceiro revisor. Nessa etapa, verificou-se as justificativas para a exclusão dos artigos e as referências e informações relevantes para a discussão foram organizadas no *Microsoft Excel*<sup>®</sup>. Todas as etapas de seleção foram registradas no fluxograma PRISMA (Page *et al.*, 2021).

A avaliação do risco de viés foi realizada utilizando a ferramenta *Prediction model Risk Of Bias Assessment Tool* (PROBAST), que avalia os participantes, os preditores do estudo, os desfechos e as análises e o *Risk Of Bias In Non-randomized Studies of Interventions* (ROBINS-I), para delineamento de estudos observacional com intervenção, que avalia a seleção dos participantes,

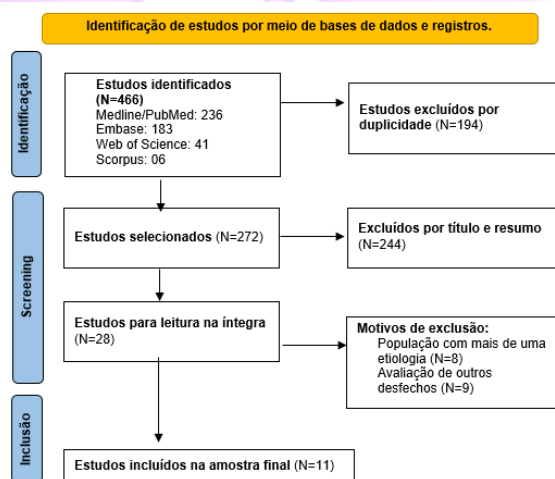
confusão, classificação e desvios da intervenção, dados incompletos, mensuração dos desfechos e relato seletivo (Sterne *et al*, 2016; Moons *et. al*, 2025). Os trabalhos foram estratificados em baixo risco, moderado ou alto risco. Procedeu-se à síntese narrativa, com agrupamento por desfechos em glicemia, observados nos artigos. Os resultados foram apresentados de forma descritiva e comparativa, com apoio de tabelas.

Para garantir os princípios éticos de pesquisa, todas as autorias dos estudos selecionados na amostra final foram devidamente respeitadas, com a devida citação. O comitê de ética em pesquisa (CEP), nesse caso, se torna dispensável, por serem dados devidamente publicados.

## RESULTADOS E DISCUSSÃO

As buscas identificaram 466 estudos potencialmente relevantes, dos quais 194 foram excluídos por duplicidade. Dos 272 estudos restantes, procedeu-se à leitura de títulos e resumos, com exclusão de 244 após aplicação dos critérios de elegibilidade. Assim, 28 artigos foram avaliados na íntegra, dos quais 17 foram excluídos. Ao final, onze estudos foram incluídos nesta revisão (Figura 1).

Figura 1 – Fluxograma PRISMA. Fortaleza, CE, Brasil, 2026.



Fonte: elaboração própria.

Os estudos incluídos, publicados nos últimos dois anos, todos conduzidos em países com alto índice de desenvolvimento humano (IDH). Quanto aos delineamentos, incluíram-se estudos observacionais, um estudo controlado não randomizado e estudos de modelagem. As tecnologias utilizadas utilizavam *Deep Learning* (DL), *Machine Learning* (ML) e redes neurais.

As intervenções envolveram diferentes tipos de CGM associados ao aprendizado tecnológico. Desse modo, construiu-se uma tabela para sintetizar os achados e os desfechos de cada estudo.


Quadro 2 – Síntese dos achados da revisão. Fortaleza, CE, Brasil, 2026.

Autor/Ano	País	IA/modelo preditivo	Desfechos principais	Principais resultados
Kobayati et al., 2026	Canadá	DL	Controle de insulina e glicose	Otimização personalizada
Sakane et al., 2026	Japão	ML	Hipoglicemia	Boa acurácia na predição, evitando excursões glicêmicas
Rodríguez de Vera et al., 2026	Espanha	ML	Hipoglicemia	Modelo validado com boa performance
Hwang et al., 2025	Coreia	DL	Predição glicêmica	Alta precisão preditiva
Darpit et al., 2025	Estados Unidos da América (EUA)	ML ( <i>Federated learning</i> )	Eventos graves de níveis glicêmicos	Boa acurácia na predição, evitando excursões glicêmicas
Marchetti et al., 2025	Itália	ML ( <i>Reinforcement learning</i> )	Controle de insulina	Otimização personalizada
Sebastian-Valles et al., 2025	Espanha	ML	<i>Time in range</i> (TIR)	Boa capacidade preditiva
Lim et al., 2025	Coreia	DL	Predição glicêmica	Alta precisão preditiva
Park et al., 2025	Coreia	ML	Eventos graves de níveis glicêmicos	Boa acurácia na predição, evitando excursões glicêmicas
Earnest et al., 2025	Austrália	ML	Controle de hemoglobina glicada (HbA1c)	Boa acurácia na predição
Ban et al., 2025	China	Redes neurais	Controle de hemoglobina glicada (HbA1c)	Boa acurácia na predição

Fonte: elaboração própria.

Em relação ao risco de viés dos estudos incluídos, os achados indicaram que a qualidade metodológica dos estudos incluídos é variável, com todos apresentando alto risco de viés em algum dos pontos observados nos instrumentos.

Figura 2 –Avaliação do risco de viés pelo PROBAST e ROBINS-I. Fortaleza, CE, Brasil, 2026.



Fonte: elaboração própria.

Observou-se, de modo geral, uma melhora do controle glicêmico, incluindo aumento do *Time in Range* (TIR), redução de episódios de hipoglicemia e melhora de HbA1c, destacando-se elevada acurácia na predição de eventos glicêmicos, como hipoglicemia e excursões hiperglicêmicas, além de potencial contribuição para a otimização do manejo terapêutico. Verificou-se um potencial impacto positivo na experiência do usuário na integração de aplicativos ou sistemas automatizados integrados à monitorização contínua da glicose.

De modo geral, as intervenções baseadas em IA associadas aos CGM demonstraram resultados promissores. Contudo, a interpretação dos achados deve considerar a heterogeneidade entre os estudos, incluindo diferenças nos algoritmos utilizados, nos desenhos de estudo e nos desfechos avaliados, além do predomínio de risco de viés elevado ou incerto em parte das evidências e do número ainda limitado de estudos incluídos.

## CONCLUSÃO

Os achados desta revisão evidenciam o potencial das tecnologias com IA no controle dos níveis de glicose no DM1, especialmente no que se refere à predição de eventos glicêmicos, personalização do tratamento e melhoria do controle metabólico. Os achados desta revisão destacam o papel crescente da IA em associação aos CGM, permitindo intervenções individualizadas e atualizadas em tempo real.

Como limitação, destaca-se o número reduzido de estudos incluídos, aliado à diversidade dos modelos e características utilizadas no estudo. Além disso, os vieses de confiabilidade identificados também devem ser considerados. Dessa forma, são necessários estudos adicionais, especialmente ensaios clínicos robustos e revisões sistemáticas com meta-análise, para consolidar as evidências e confirmar o impacto dessas tecnologias na prática clínica.

## REFERÊNCIAS

BAN, T. et al. GLM-DM: language model boosted neural networks for HbA1c trend prediction in diabetes mellitus. **Future Sci OA.**, v. 11, n. 1, e 2567166, 2025.

CENTRE FOR REVIEWS AND DISSEMINATION (CRD). **PROSPERO**: International prospective register of systematic reviews. York: University of York, 2024.

DARPIT, A. et al. A personalized federated learning-based glucose prediction algorithm for high-risk glycemic excursion regions in type 1 diabetes. **Sci Rep**, v. 185, n. 1, e 38376, 2025.

EARNEST, A. et al. Machine learning techniques to predict diabetic ketoacidosis and HbA1c above 7% among individuals with type 1 diabetes: a large multi-centre study in Australia and New Zealand. **Nutr Metab Cardiovasc Dis.**, v. 35, n. 7, e 103861, 2025.

HWANG, J. et al. Generalized multi-task learning framework for glucose forecasting and hypoglycemia detection using simulation to reality. **NPJ Digital Medicine**, v. 8, e612, 2025.

KOBAYATI, A. et al. Inter- and intra-physician variability in insulin injection adjustments compared with Bayesian algorithm recommendations in type 1 diabetes. **Diabetologia**, v.69, n. 4, p 872-882, 2025.

LIM, H. et al. A deep learning framework for virtual continuous glucose monitoring and glucose prediction based on life-log data. **Sci Rep**, v. 15, e16290, 2025.

LIN, R.; et al. Continuous glucose monitoring: a review of the evidence in type 1 and 2 diabetes mellitus. **Diabet Med.**, v. 38, n. 5, e14528, 2021.

MARCHETTI, G. et al. Deep reinforcement learning for type 1 diabetes: dual PPO controller for personalized insulin management. **Artificial Intelligence in Medicine**, v. 191, e110147, 2025.

MOONS, K. G. M. et al. PROBAST+AI: an updated quality, risk of bias, and applicability assessment tool for prediction models using regression or artificial intelligence methods. **BMJ**, v. 388, e082505, 2025.

PAGE, M. J. et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. **BMJ**, v. 372, n. 71, 2021.

PARK, S. et al. Identification of clinically meaningful automatically detected postprandial glucose excursions in individuals with type 1 diabetes using personal continuous glucose monitoring. **Journal of Diabetes Science and Technology**, v. 229, e112951, 2025.

RODRÍGUEZ DE VERA, M. et al. Development and validation of nomogram-based predictive models for severe hypoglycemia in adults with type 1 diabetes treated with multiple daily injections: the SEHYPAN study. **Endocrinol Diabetes Metab.**, v. 42, n. 3, e70151, 2026.

SAKANE, N. et al. Identification of severe hypoglycemia in adults with type 1 diabetes using CGM-based machine learning: evidence from the FGM-Japan study. **Diabet. Int**, v.17, n.2, e21, 2026.

SOCIEDADE BRASILEIRA DE DIABETES. Diretriz da Sociedade Brasileira de Diabetes 2025. São Paulo: SBD, 2025. Disponível em: <https://diretriz.diabetes.org.br/>. Acesso em: 28 mar. 2026.

SEBASTIAN-VALLES, R. et al. Predicting time in range without hypoglycaemia using a risk calculator for intermittently scanned CGM in type 1 diabetes. **Endocrinol Diabetes Metab.**, v. 8, n. 1, e70020, 2025.

TERWEE, C. B. et al. Quality criteria were proposed for measurement properties of health status questionnaires. **J Clin Epidemiol.**, v. 60, n. 1, p. 34–42, 2007.

VETTORETTI, M.; et al. Advanced diabetes management using artificial intelligence and continuous glucose monitoring sensors. **Sensors**, v. 20, n. 14, p. 3870, 2020.