



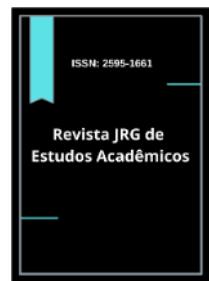
ISSN: 2595-1661

ARTIGO

Listas de conteúdos disponíveis em [Portal de Periódicos CAPES](#)

# Revista JRG de Estudos Acadêmicos

Página da revista:  
<https://revistajrg.com/index.php/jrg>



## A implementação da inteligência artificial no manejo da diabetes mellitus gestacional

The Implementation of Artificial Intelligence in the Management of Gestational Diabetes Mellitus

DOI: 10.55892/jrg.v9i20.2886

ARK: 57118/JRG.v9i20.2886

Recebido: 23/01/2026 | Aceito: 26/01/2026 | Publicado on-line: 28/01/2026

**Letícia Fernanda Pacheco da Costa<sup>1</sup>**

<https://orcid.org/0009-0006-1600-3515>  
 <http://lattes.cnpq.br/5017461335835814>  
Universidade Tiradentes, SE, Brasil  
E-mail: leticia.pacheco@souunit.com.br

**Arthur Vinícius Feitosa Santos<sup>1</sup>**

<https://orcid.org/0009-0001-3025-5077>  
 <http://lattes.cnpq.br/2920203673814748>  
Universidade Tiradentes, SE, Brasil  
E-mail: arthur.vinicius04@souunit.com.br

**Giovanna dos Reis Martins Barros<sup>1</sup>**

<https://orcid.org/0009-0005-2778-7012>  
 <https://lattes.cnpq.br/8023219081114644>  
Universidade Tiradentes, SE, Brasil  
E-mail: giovanna.reis@souunit.com.br

**Laís Kethleen Martins Santos<sup>1</sup>**

<https://orcid.org/0009-0006-8033-145X>  
 <https://lattes.cnpq.br/0186231714506307>  
Universidade Tiradentes, SE, Brasil  
E-mail: laiskethleen@gmail.com

**Pedro Alexandre Leite de Almeida<sup>1</sup>**

<https://orcid.org/0009-0001-3025-5077>  
 <http://lattes.cnpq.br/4571104943152640>  
Universidade Tiradentes, SE, Brasil  
E-mail: pedroalexandre1604@gmail.com

**Any Eduarda Nanes de Oliveira Farias<sup>2</sup>**

<https://orcid.org/0009-0004-5489-6209>  
 <http://lattes.cnpq.br/2231959528798598>  
Universidade Tiradentes, SE, Brasil  
E-mail: any.eduarda@souunit.com.br

**Lívia Cardoso Lima<sup>1</sup>**

<https://orcid.org/0009-0001-4248-589X>  
 <http://lattes.cnpq.br/1511155868452404>  
Universidade Tiradentes, SE, Brasil  
E-mail: livislilima@gmail.com

**Felipe Mendes de Andrade de Carvalho<sup>3</sup>**

<https://orcid.org/0000-0002-7360-7925>  
 <http://lattes.cnpq.br/3603630253289567>  
Universidade Tiradentes, SE, Brasil  
E-mail: felipe\_mendesdeandrade@hotmail.com

## Resumo

A Diabetes Mellitus Gestacional (DMG) é caracterizada por hiperglicemia decorrente de resistência à insulina ou de déficit de secreção durante a gestação, influenciada por hormônios placentários e adipocinas. Com prevalência de até 25% no mundo e cerca de 18% no Brasil, está associada a complicações materno-fetais. Em países em desenvolvimento, a assistência pré-natal inadequada reforça a importância do diagnóstico precoce. O rastreio tradicional apresenta limitações, e a Inteligência Artificial (IA) surge como ferramenta promissora para triagem e manejo da DMG. Com isso, o objetivo desse artigo foi analisar o impacto da IA no diagnóstico precoce, manejo e tratamento da DMG. Para isso, foi realizada uma revisão integrativa qualitativa e descritiva, em seis etapas, com pergunta norteadora elaborada pela estratégia PICO. A busca foi realizada nas bases PubMed e BVS, com os descritores “Artificial Intelligence” e “Diabetes Gestacional”, incluindo estudos originais publicados entre 2020 e 2025, em

<sup>1</sup> Graduando(a) em medicina pela Universidade Tiradentes.

<sup>2</sup> Graduada em Biomedicina em 2021. Licenciada em Biologia em 2024. Mestre em Biotecnologia Industrial em 2023. Doutoranda em Biotecnologia Industrial pela Universidade Tiradentes.

<sup>3</sup> Graduado em Biomedicina em 2017. Mestre em 2019 e Doutor em 2023 em Saúde e Ambiente pela Universidade Tiradentes.



inglês, português e espanhol, de acesso gratuito e alinhados à realidade brasileira. Dessa forma, foram identificados 84 artigos, dos quais 27 compuseram a amostra final. Observou-se aumento nas publicações, especialmente em 2022 e 2023, com predominância de estudos internacionais, principalmente da China. As abordagens mais frequentes utilizaram algoritmos de aprendizado de máquina (XGBoost, redes neurais, AutoML) para predição da DMG, identificação de fatores de risco e previsão de desfechos neonatais. Alguns estudos também propuseram aplicativos móveis para rastreio e gestão. Portanto, a IA apresenta potencial para aprimorar a predição e o manejo precoce da DMG, oferecendo diagnósticos mais precisos e personalizados. Contudo, apesar dos resultados promissores, são necessárias validações externas, padronização metodológica e políticas que assegurem integração ética e equitativa dessas ferramentas na atenção pré-natal.

**Palavras-chave:** avaliação de riscos; diabetes mellitus gestacional; inovação; inteligência artificial; saúde materna.

### **Abstract**

*Gestational Diabetes Mellitus (GDM) is characterized by hyperglycemia resulting from insulin resistance or impaired insulin secretion during pregnancy, influenced by placental hormones and adipokines. With a prevalence of up to 25% worldwide and approximately 18% in Brazil, it is associated with maternal and fetal complications. In developing countries, inadequate prenatal care reinforces the importance of early diagnosis. Traditional screening methods have limitations, and Artificial Intelligence (AI) has emerged as a promising tool for the screening and management of GDM. Therefore, the aim of this article was to analyze the impact of AI on the early diagnosis, management, and treatment of GDM. To this end, a qualitative and descriptive integrative review was conducted in six stages, guided by a research question formulated using the PICO strategy. The search was carried out in the PubMed and VHL databases using the descriptors "Artificial Intelligence" and "Gestational Diabetes," including original studies published between 2020 and 2025, in English, Portuguese, and Spanish, with free full-text access and aligned with the Brazilian context. A total of 84 articles were identified, of which 27 comprised the final sample. An increase in publications was observed, especially in 2022 and 2023, with a predominance of international studies, mainly from China. The most frequent approaches employed machine learning algorithms (XGBoost, neural networks, AutoML) for GDM prediction, identification of risk factors, and prediction of neonatal outcomes. Some studies also proposed mobile applications for screening and management. Therefore, AI shows potential to improve the early prediction and management of GDM, providing more accurate and personalized diagnoses. However, despite the promising results, external validation, methodological standardization, and policies to ensure the ethical and equitable integration of these tools into prenatal care are still needed.*

**Keywords:** risk assessment; gestational diabetes mellitus; innovation; artificial intelligence; maternal health.



## 1. Introdução

A diabetes mellitus gestacional (DMG) é um distúrbio endócrino-metabólico caracterizado por hiperglicemia decorrente de resistência periférica à insulina e/ou deficiência na sua secreção, manifestando-se exclusivamente durante a gestação. Trata-se de uma das complicações metabólicas mais comuns na gravidez, com impacto significativo na saúde materna e fetal, sendo cada vez mais relevante diante dos hábitos de vida inadequados, características demográficas e desigualdades no acesso à assistência pré-natal (Zanetti et al., 2024).

A etiologia da DMG envolve a interação entre fatores genéticos e ambientais, incluindo obesidade, sedentarismo, idade materna avançada e condições socioeconômicas desfavoráveis (Kumar et al., 2022; Chan et al., 2023; Gallardo-Rincón et al., 2023; Kang et al., 2023). A insuficiência na assistência pré-natal, frequente em populações vulneráveis, potencializa o risco de desenvolvimento da doença e agrava seus impactos.

As repercussões da DMG afetam tanto a mãe quanto o feto. Nas gestantes, associa-se o aumento de complicações obstétricas, como cesariana e parto instrumental, ao maior risco de doenças cardiovasculares a longo prazo. Para o feto, destacam-se macrossomia, predisposição à obesidade infantil e elevação do risco de diabetes mellitus tipo 2 (DM2) na vida adulta (Ye et al., 2020; Wu et al., 2021; Cubillos et al., 2023; Xing et al., 2024). Evidências indicam que a detecção e intervenção ainda no primeiro trimestre podem reduzir de 18% a 62% as complicações relacionadas à doença (Hu et al., 2023).

Diante do exposto, o manejo da DMG tradicionalmente envolve rastreamento de indicadores clínicos, acompanhamento laboratorial e controle nutricional. Contudo, a inteligência artificial (IA) emerge como recurso inovador, capaz de aprimorar a triagem, o diagnóstico, o monitoramento glicêmico e até a descoberta de novas abordagens terapêuticas (Iqbal et al., 2023). Modelos preditivos baseados em IA permitem identificar precocemente gestantes em risco, favorecendo intervenções preventivas, de menor custo e maior efetividade, especialmente em contextos de baixa e média renda (Gallardo-Rincón et al., 2023).

## 2. Metodologia

Trata-se de uma revisão integrativa da literatura, de natureza qualitativa e abordagem descritiva. A elaboração deste artigo seguiu as seguintes etapas: 1- Elaboração da questão norteadora; 2 - Busca nas bases de dados; 3 - Análise crítica dos estudos incluídos; 4 - Apresentação da revisão integrativa.

Realizou-se a busca da literatura nas bases de dados: Biblioteca Virtual em Saúde (BVS) e PubMed (*US National Library of Medicine*), com filtro para os anos de 2020 a 2025. Para tanto, os descritores das bases Descritores em Ciências da Saúde (DeCS) e *Medical Subject Headings* (MeSH) selecionados foram: "Artificial Intelligence" e "Diabetes Gestational". Em seguida, foram ligados pelo operador booleano "AND", para selecionar os periódicos que contemplem as duas temáticas.

Para a pesquisa, definiu-se a questão norteadora "Qual é o impacto do uso da inteligência artificial no diagnóstico precoce, manejo e tratamento do diabetes mellitus gestacional em comparação com métodos tradicionais?", estabelecida por meio da estratégia PICO (Santos, 2007), em que: P (população) corresponde às gestantes com DMG; I (intervenção) refere-se ao uso de IA no diagnóstico, manejo ou tratamento; C (comparação) diz respeito aos métodos tradicionais e ao manejo convencional da DMG (sem uso de IA); e O (resultado) considera o diagnóstico precoce, a melhora no manejo e a otimização do tratamento.



Foram incluídas publicações que seguissem os seguintes critérios: a) artigos originais; b) período de publicação: de 2020 a 2025; c) idiomas: inglês, português e espanhol; d) disponibilidade gratuita; e) respondessem à pergunta norteadora. Como critérios de exclusão estabeleceu-se: a) estudos não aplicáveis no cenário brasileiro; b) tipo de estudo: revisões narrativas, editoriais, cartas ao leitor, TCC, dissertações, teses e periódicos repetidos.

### 3. Resultados

Na busca com descritores DeCS-MeSH “Artificial Intelligence” e “Diabetes Gestational”, foram avaliados 61 periódicos na base PubMed e 23 na BVS-Salud, desses, foram utilizados 35 e 1, respectivamente, totalizando 36 artigos selecionados para leitura na íntegra, após a filtragem de 9 artigos que constavam em ambas bases. Desse modo, 6 artigos foram excluídos pela pouca relevância, e, por fim, a síntese da revisão integrativa foi realizada com 27 estudos (Quadro 01).

A análise identificou uma maior concentração de publicações entre 2022 e 2023 (48,1%), com cinco estudos em 2020, cinco em 2021, sete em 2022, seis em 2023, e dois estudos em cada um dos anos de 2024 e 2025. Quanto à distribuição geográfica, os trabalhos foram conduzidos em diversos países, incluindo Chile, China, Coreia do Sul, Estados Unidos, Grécia, Irã, Irlanda, Israel, México, Reino Unido, Rússia, Singapura e Turquia, destacando-se a China, responsável por nove artigos (33,3%) do total analisado.

**Quadro 01:** Distribuição dos estudos segundo Autor, Título, Objetivo e País da Realização/Ano da Publicação.

AUTOR	TÍTULO	OBJETIVO	PAÍS/ ANO
MCLAREN, R. et al.	Uma nova e precisa ferramenta de perfilção para a predição da diabetes gestacional	Desenvolver modelos preditivos de DMG baseados em IA.	Estados Unidos, 2020
SHEN, J. et al.	Um aplicativo inovador baseado em inteligência artificial para o diagnóstico do Diabetes Mellitus Gestacional (GDM-AI): Estudo de Desenvolvimento	Investigar a implementação de um algoritmo de IA para diagnóstico de DMG e estabelecer um aplicativo baseado no algoritmo de IA.	China, 2020
YE, Y. et al.	Comparação de métodos de aprendizado de máquina e regressões logísticas convencionais para prever diabetes gestacional usando dados clínicos de rotina: Um estudo de coorte retrospectivo	Usar métodos de aprendizado de máquina para prever a DMG e comparar seu desempenho com o das regressões logísticas.	China, 2020
DALEY, B. J. et al.	Aplicativos de saúde para diabetes mellitus gestacional que oferecem suporte à decisão clínica ou inteligência artificial: Uma revisão de escopo.	Identificar aplicativos recentes de mHealth suportados por IA ou suporte de decisão clínica habilitado para IA.	Reino Unido, 2021
WU, Y. et al.	Predição precoce do diabetes mellitus gestacional na população chinesa por meio de aprendizado de máquina avançado	Estabelecer modelos eficazes para prever a DMG precoce.	China, 2021
WANG, J. et al.	Um modelo inicial para prever o risco de diabetes mellitus gestacional na ausência de	Construir um modelo inicial para prever a DMG no primeiro trimestre para o	China, 2021



	índices de exames sanguíneos: Aplicação em centros de atenção primária à saúde	centro de cuidados primários de saúde.	
RAMAKRISHNAN, R.; RAO, S.; HE, J.	Preditores de saúde perinatal utilizando inteligência artificial: Uma revisão	Apresentar uma visão geral das evidências para aplicação de IA em saúde perinatal.	Reino Unido, 2021
POPOVA, P. et.al.	Protocolo do ensaio para o estudo do sistema de recomendação DiaCompanion com recomendações dietéticas personalizadas para mulheres com diabetes mellitus gestacional (DiaCompanion I)	Esclarecer o efeito do uso do DiaCompanion I nos níveis glicêmicos em mulheres com DMG.	Rússia, 2021
KIM, B. et al.	Efeito de uma intervenção em saúde baseada em aplicativo de smartphone para o gerenciamento da saúde de mães de alto risco: Protocolo de estudo para um ensaio clínico randomizado	Direcionar a eficácia de um aplicativo de smartphone para intervenções de cuidados de saúde em mães de alto risco.	Coréia do Sul, 2022
KUMAR, M. et al.	Modelo preditivo de risco pré-concepcional baseado em Aprendizado de Máquina Automatizado (AutoML) para guiar a intervenção precoce no Diabetes Mellitus Gestacional	Construir um preditor de DMG baseado na pré-conceição para permitir a intervenção precoce e avaliar as associações dos principais preditores com DMG com os resultados adversos do nascimento	Singapura, 2022
PERIYATHAMBI, N. et al.	Predição por aprendizado de máquina da não adesão ao rastreamento glicêmico pós-parto e do risco subsequente de diabetes tipo 2 após diabetes gestacional	Identificar os fatores associados à não participação no teste imediato de glicose pós-parto usando um algoritmo de aprendizado de máquina após a gravidez com DMG.	Reino Unido, 2022
ZHANG, J.; WANG, F.	Predição do Diabetes Mellitus Gestacional usando algoritmos de aprendizado em cascata e ensemble	Desenvolver e validar um modelo preditivo para estimar o risco de DMG utilizando técnicas de aprendizado de máquina.	China, 2022
KUMAR, M. et al.	Modelagem centrada na população de predição de risco para diabetes mellitus gestacional: uma abordagem de aprendizado de máquina	Avaliar a capacidade preditiva das diretrizes existentes do NICE do Reino Unido para avaliar o risco de DMG em mulheres de Singapura e desenvolver um modelo preditivo não invasivo com aprendizado de máquina.	Singapura, 2022
DU, Y. et al.	Um sistema explicável de suporte à decisão clínica baseado em aprendizado de máquina para a predição do diabetes mellitus gestacional	Aplicar o aprendizado de máquina para desenvolver um CDSS que preveja o risco de DMG em um grupo de alto risco de mulheres com sobrepeso e obesidade para identificar aqueles que podem se beneficiar das	Irlanda, 2022



		estratégias de prevenção no início da gravidez.	
LIAO, L. et al.	Desenvolvimento e validação de modelos preditivos para a modalidade de tratamento do diabetes gestacional usando aprendizado de máquina supervisionado: Um estudo de coorte de base populacional	Desenvolver modelos preditivos usando algoritmos de aprendizado de máquina para prever indivíduos que precisam de tratamento farmacológico intensivo	Estados Unidos, 2022
GALLARDO-RINCÓN, H. et al.	MIDO GDM: Inovador modelo preditivo para o desenvolvimento de diabetes gestacional em mulheres mexicanas baseado em inteligência artificial	Desenvolver um modelo preditivo de DMG entre mulheres grávidas no México.	México, 2023
HOURI, O. et al.	Predição de desfechos perinatais adversos em gestações complicadas por diabetes gestacional usando algoritmo de rede neural	Utilizar um modelo de rede neural para prever resultados neonatais adversos em gestações complicadas pela DMG.	Israel, 2023
KANG, B. et al.	Predição do diabetes mellitus gestacional em mulheres asiáticas usando algoritmos de aprendizado de máquina	Desenvolver um algoritmo de aprendizado de máquina para previsão de DMG em mulheres asiáticas de acordo com o período gestacional que pode ser aplicado às mulheres coreanas para calcular o risco individualizado de DMG.	Coreia, 2023
KURT, B. et al.	Predição do diabetes gestacional usando deep learning, otimização Bayesiana e técnicas tradicionais de aprendizado de máquina	Desenvolver um sistema de diagnóstico clínico para identificar pacientes no grupo de risco de DMG e reduzir aplicações desnecessárias de teste oral de tolerância à glicose para mulheres grávidas que não estão no grupo de risco de DD usando algoritmos de aprendizado profundo.	Turquia, 2023
HU, X. et al.	Modelo de previsão para diabetes mellitus gestacional usando o algoritmo de aprendizado de máquina XGBoost.	Desenvolver o modelo de aprendizado de máquina para prever diabetes mellitus gestacional em comparação com um modelo usando o método tradicional de regressão logística (LR).	China, 2023



CUBILLOS, G. et al.	Desenvolvimento de modelos de aprendizado de máquina para prever o risco de diabetes gestacional na primeira metade da gravidez.	Desenvolver modelos de aprendizado de máquina (ML), para a previsão precoce da DMG usando variáveis amplamente disponíveis, facilitando a intervenção precoce e possibilitando a aplicação dos modelos de previsão em locais onde não há acesso a exames mais complexos.	Chile, 2023
CHAN, Y. et al.	Uma abordagem de aprendizado de máquina para previsão precoce do diabetes mellitus gestacional usando conteúdos elementares das unhas.	Prever o risco de diabetes mellitus gestacional pelo conteúdo elementar nas unhas e na urina com análise de aprendizado de máquina.	China, 2023
MAVRELI, D. et al.	Proteômica quantitativa comparativa revela biomarcadores candidatos para a previsão precoce do diabetes mellitus gestacional: um estudo preliminar.	Identificar proteínas diferencialmente expressas (DEPs) no plasma materno do 1º trimestre entre mulheres grávidas em risco de diabetes mellitus gestacional.	Grécia, 2020
KAYA, Y. et al.	Predição precoce do diabetes mellitus gestacional por modelos de aprendizagem de máquina.	Determinar o algoritmo baseado em aprendizado de máquina de melhor desempenho para prever DMG com características sociodemográficas e obstétricas no período pré-concepcional.	Turquia, 2024
XING, J. et al.	Aprimoração da avaliação de risco e do tratamento do diabetes mellitus gestacional por meio do GDMPredictor: Uma abordagem de aprendizado de máquina	Desenvolver e validar uma ferramenta baseada em aprendizado de máquina, chamada GDMPredictor, para prever o risco de DMG em mulheres grávidas e personalizar recomendações de tratamento.	China, 2024
BIGDELI, S. K. et al.	Predição da diabetes mellitus gestacional no primeiro trimestre usando algoritmos de aprendizado de máquina: um estudo transversal em um centro hospitalar de saúde reprodutiva no Irã.	Criar um modelo de previsão precoce para DMG no primeiro trimestre da gravidez.	Irã, 2025
ZHAO, M. et al.	Valor preditivo do aprendizado de máquina para a progressão do diabetes mellitus gestacional para diabetes tipo 2: Uma revisão sistemática e meta-análise	Explorar o valor preditivo inicial dos modelos de aprendizado de máquina para a progressão da DMG para o diabetes mellitus tipo 2 (T2DM).	China, 2025

**Fonte:** Autores, 2025.



Por fim, para análise dos benefícios e implicações do uso da IA no manejo da DMG foram propostas duas categorias de discussão: a IA como instrumento de previsão de risco para DMG e a aplicação da IA no manejo, monitoramento e tratamento da DMG.

#### **4. Discussão**

O presente artigo sintetiza estudos relevantes publicados nos últimos anos que apontam a implementação da IA como ferramenta na previsão, manejo, monitoramento e tratamento da DMG. Trata-se de uma patologia frequente durante a gravidez, que pode estar associada a sérias complicações maternas e neonatais, incluindo o risco de pré-eclâmpsia, partos prematuros e malformações congênitas.

Nesse contexto, a aplicação de novas tecnologias baseadas em métodos da IA, principalmente preditivas, têm sido cada vez mais incorporada à prática clínica nos últimos anos, consolidando-se como ferramentas valiosas, trazendo uma série de benefícios, tanto sociais quanto econômicos. Sendo assim, foram analisados estudos com o objetivo de apresentar as evidências sobre o uso da IA na DMG, destacando como essa tecnologia contribui para o diagnóstico precoce e um melhor controle na evolução da doença.

#### **Tecnologias na detecção precoce da DMG**

A aplicação e incorporação da IA na área da saúde está sendo cada vez mais utilizada para facilitar e solucionar problemas na era digital, especialmente, em relação à DMG e à saúde gestacional (Gallardo-Rincón et al., 2023). A incorporação de modelos da IA vem sendo aplicada para permitir a detecção precoce e o início do tratamento, oferecendo, assim, respostas mais rápidas às demandas clínicas. Atualmente, o padrão-ouro se reserva ao teste oral de tolerância à glicose (TOTG) realizado entre 24 e 28 semanas da gravidez, em conjunto com outros parâmetros clínicos e biomarcadores séricos, os quais nem todas as populações conseguem ter acesso (Mavreli et al., 2020).

Dessa forma, Gallardo Rincón e colaboradores (2023), em um estudo clínico randomizado controlado chamado “Cuido Mi Embarazo”, realizado com 1.709 grávidas no México, criou uma ferramenta para prever o risco de desenvolvimento de DMG com menor dependência de equipamentos médicos e exames laboratoriais, o denominando-o de “*Medición Integrada para la Detección Oportuna (MIDO)*” para predição de DMG.

O MIDO é um algoritmo de IA de rede neural artificial (ANN), alimentado por dados de fácil acesso (idade, histórico familiar de DM2, diagnóstico prévio de hipertensão, índice de massa corporal pré-gestacional, semana gestacional, paridade, peso ao nascer do último filho e glicemia capilar aleatória). O modelo apresenta alta precisão (70,3%), cujo objetivo é a detecção precoce do alto risco, permitindo a promoção de intervenções preventivas nos estágios iniciais da gravidez a partir das variáveis coletadas. Ademais, busca incorporar a MIDO GDM em um ecossistema de plataformas digitais interconectadas, integrando-as no sistema de saúde do país e facilitando o acesso tanto aos profissionais de saúde quanto aos pacientes (Gallardo-Rincón et al., 2023).

Com abordagem semelhante, McLaren e colaboradores (2020) realizaram um estudo nos Estados Unidos utilizando a plataforma de IA “Safe Pregnancy Artificial Intelligence – SPAI”, desenvolvida pela GynInUs, Ltd. Esse projeto foi treinado com dados de diversas fontes como as notas de admissão, os registros de pré-natais, ambulatoriais e valores laboratoriais coletados dos prontuários eletrônicos de um centro médico entre 2001 e 2018.

O SPAI é um algoritmo de triagem exclusivo baseado em fórmulas matemáticas, desenvolvido para prever a probabilidade das gestantes adquirirem DMG, inclusive na



fase pré-gestacional. Esse modelo utiliza tanto fatores de risco já conhecidos da doença quanto novos parâmetros antes não correlacionados, como religião, número de gestações anteriores combinadas com histórico de DMG, ordem de nascimento, além de marcadores laboratoriais (hemoglobina glicada, progesterona, triglicerídeos, T4 livre, TSH etc) e outras variáveis que podem não ter sido consideradas (McLaren et al., 2020).

Adicionalmente, Kumar e colaboradores (2022) propuseram um modelo preditivo de risco baseado em aprendizado de máquina automatizado (AutoML), desenvolvido para diagnosticar a ocorrência de DMG antes da concepção. Esse, a partir da análise de dados de 222 gestantes asiáticas alcançou uma excelente capacidade preditiva, utilizando apenas quatro variáveis: hemoglobina glicada (HbA1c), pressão arterial média, glicemia em jejum e razão triglicérides/HDL.

O estudo demonstrou que o controle adequado da HbA1c no período pré-concepcional pode reduzir o risco de DMG e parto prematuro. Assim sendo, a inclusão de HbA1c como principal preditor reforça sua importância clínica, pois se mostrou mais confiável do que a glicemia de jejum na estratificação de risco. Destacando ainda a relevância de analisar outros precursores metabólicos na fisiopatologia da DMG, como resistência à insulina e disfunção hepática (Kumar et al., 2022).

Outrossim, Xing et al (2024) elaboraram e validaram uma ferramenta baseada em aprendizado de máquina (ML) para prever o risco de DMG e personalizar recomendações de tratamento, o GDMPredictor. Esse modelo foi treinado com dados de 3.467 gestantes, totalizando 5.649 registros clínicos e bioquímicos, e analisou parâmetros bioquímicos essenciais (A1MG, BMG, CysC, CO<sub>2</sub>, TBA, FPG e CREA) para estratificar o risco de DMG e orientar intervenções precoces. O GDMPredictor demonstrou alta precisão, com uma área sob a curva (AUC) de 0,967, superando abordagens tradicionais baseadas apenas em critérios clínicos. Além disso, é capaz de prever o risco de DMG em qualquer fase da gestação entre 1 e 24 semanas, proporcionando recomendações individualizadas para cada paciente.

Ye et al. (2020), buscando avaliar a eficácia das abordagens tecnológicas na área, desenvolveram um modelo preditivo baseado em pontos de corte, comparando a eficácia de algoritmos de ML com a regressão logística. Os principais fatores preditores incluíram glicemia de jejum, HbA1c, triglicerídeos e índice de massa corporal (IMC) materno. Apesar de o ML ter sido eficiente na captação de relações não lineares entre variáveis, ele não superou a regressão logística na predição da DMG.

Um dos achados mais relevantes foi que mulheres com valores preditivos inferiores a 0,3 poderiam evitar o TOTG, enquanto valores acima de 0,7 indicaram maior risco de desfechos adversos, incluindo macrossomia, parto prematuro e pré-eclâmpsia. Assim, o modelo pode otimizar a estratificação de risco e reduzir a necessidade de exames diagnósticos invasivos para mulheres de baixo risco, embora estudos prospectivos sejam necessários para validar e consolidar a abordagem na prática clínica (Ye et al., 2020).

O estudo de Kaya et al. (2024) instituíram um modelo preditivo baseado em variáveis clínicas simples, como glicemia na primeira visita, IMC materno e histórico familiar de diabetes, visando identificar mulheres sem histórico obstétrico de alto risco que poderiam desenvolver DMG. A abordagem demonstrou alta sensibilidade, permitindo a identificação de todos os casos em nulíparas, garantindo que nenhuma gestante em risco fosse negligenciada. No entanto, essa abordagem gerou um número elevado de falsos positivos, aumentando custos com testes adicionais. A pesquisa ressalta a importância de ajustes na modelagem para otimizar a relação entre sensibilidade e especificidade. Além disso, por ter sido desenvolvido com base em uma população turca, sua aplicação em



outros contextos, como o Brasil, exigiria adaptações para contemplar diferenças étnicas e variabilidade sociodemográfica.

Corroborando com essa abordagem, foi analisado o estudo de Kumar et al., 2022 que avaliou a aplicabilidade das diretrizes do National Institute for Health and Care Excellence (NICE) do Reino Unido para prever DMG em mulheres de Singapura. Os resultados indicaram que o desempenho preditivo das diretrizes do NICE foi insuficiente para a população asiática. Em resposta a essa limitação, os pesquisadores desenvolveram um modelo mais específico para essa etnia, incorporando um painel não invasivo (primeiro nível) com quatro fatores: pressão arterial média no primeiro trimestre, idade materna, etnia e histórico prévio de DMG. Foi possível observar um desempenho significativamente superior, com uma AUC de 0,82 (IC 95% 0,71-0,93).

Também desenvolveram um nível de predição invasivo, que incluiu testes laboratoriais avançados, como a adiponectina. A baixa concentração desse biomarcador foi associada a resistência à insulina e acúmulo de gordura visceral, um fator fisiopatológico relevante no desenvolvimento de DMG em mulheres asiáticas. O estudo também sugeriu que o aumento do consumo de laticínios no meio da gestação poderia representar um fator de risco modificável para DMG, embora essa conclusão exija mais investigação devido ao possível viés de recordação alimentar (Kumar et al., 2022).

Desse modo, os diversos modelos de predição, como aprendizado de máquina, random forest e regressão logística, podem ser incorporados aos sistemas de saúde para automatizar a estratificação de risco e otimizar o tratamento, de modo a guiar intervenções precoces e personalizadas (Bigdelli et al., 2025). No entanto, apesar do alto desempenho preditivo, essas ferramentas precisam ser validados em diferentes sistemas de saúde para garantir sua generalização, além de que a falta de padronização no uso de algoritmos e a escassez de validações clínicas em populações diversas limitam a ampliação dessas tecnologias para diferentes contextos clínicos.

Outros desafios na implementação prática incluem a integração desses modelos em fluxos de trabalho clínicos, a necessidade de aceitação por parte dos profissionais de saúde e o acesso limitado a dispositivos móveis e internet. Além disso, a impossibilidade de prever individualmente a necessidade de insulinoterapia, devido ao tamanho da amostra, configura-se como um impasse para a aplicação prática do estudo (Daley et al., 2021; Ramakrishnan; Rao; He, 2021).

### **IA como estratégia para contextos com recursos limitados**

Nos países em desenvolvimento, a falta de acesso a serviços de saúde e escassez de profissionais qualificados para a realização do pré-natal podem dificultar a identificação precoce de complicações, como a DMG. Shen e colaboradores (2020), em um estudo de caso-controle, buscaram desenvolver uma ferramenta de diagnóstico de DMG usando tecnologia de IA, com a intenção de atender mulheres que vivem em regiões de poucos recursos. A avaliação contou com a análise do desempenho de modelos avançados de IA como: máquina de vetores de suporte (SVM), floresta aleatória, AdaBoost, k-vizinhos mais próximos (kNN), *Bayes ingênuo* (NB), árvore de decisão, regressão logística (LR), *eXtreme gradient boosting* (XGBoost) e *gradient boosting decision tree* (GBDT).

Os resultados obtidos com o uso desses algoritmos foram comparados com diagnósticos realizados anteriormente, segundo os critérios estabelecidos pela *American Diabetes Association* (ADA) de 2011, para a população estudada. Vale destacar que, nos modelos de IA avaliados, a combinação utilizada para diferenciar DMG de não DMG se baseava exclusivamente na idade materna e na glicemia em jejum (Shen et al., 2020). Como resultado da amostra, o SVM manteve alto desempenho em precisão,



especificidade, valor preditivo positivo (VPP), razão de verossimilhança positiva e área sob a curva característica de operação do receptor (AUROC) compatíveis com diagnósticos corretos, evidenciando o potencial do algoritmo SVM para tomar decisões de diagnóstico altamente precisas (Shen et al., 2020).

Embora os critérios da ADA 2011 sejam amplamente utilizados, sua aplicação exige recursos extensivos, tornando-os pouco viáveis em contextos subdesenvolvidos. Comparativamente, os algoritmos de IA possibilitaram diagnósticos precisos e em tempo real utilizando apenas dois preditores, aumentando a viabilidade de aplicação em áreas com recursos limitados. Portanto, a IA representa uma solução promissora para reduzir atrasos no diagnóstico, ampliar o aconselhamento preventivo e potencialmente otimizar o tratamento de gestantes com risco de DMG em populações carentes (Shen et al., 2020).

### **Predição dos desfechos gestacionais**

A tecnologia de IA também pode contribuir para a previsão de desfechos maternos-fetais após o diagnóstico de DMG. Nesse sentido, Houri et al. (2023), em estudo clínico randomizado, avaliaram a eficácia de um modelo de rede neural para previsão de resultados neonatais adversos em gestações complicadas pela DMG, evidenciaram uma precisão de 82% no momento do diagnóstico e 91% no parto. Os resultados foram obtidos através de variáveis básicas, disponíveis durante o acompanhamento pré-natal, incluindo idade materna, paridade, número de gestação, IMC pré-gestacional, valores de GCT (teste de desafio à glicose de 50 g) e TOTG de 100 g, peso materno (pré-gestacional, no diagnóstico de DMG e parto), tipo de modalidade de tratamento para DMG (dieta ou farmacológico) e grau de controle glicêmico (categorizado em ruim ou bom). Dentre os preditores analisados, o GCT apresentou melhor resposta por apresentar um valor médio maior no grupo com desfechos neonatais adversos em comparação ao normal ( $168,04 \pm 32,81$  vs.  $161,44 \pm 25,26$  mg/dL,  $p = 0,008$ ), os outros parâmetros, no entanto, não foram significativamente diferentes.

O modelo de rede neural abordado conta com um algoritmo de ML que permite o treinamento da IA através de exemplos reais, realizando cálculos e indicando a probabilidade de ocorrências de complicações neonatais com base em fatores maternos. Esse sistema avalia ainda os possíveis desfechos gestacionais, incluindo bebês grandes ou pequenos para a idade gestacional (GIG ou PIG), distocia de ombro, pH do cordão umbilical  $< 7,2$ , admissão em unidade de terapia intensiva neonatal, hipoglicemias neonatais ( $< 45$  mg/dL), síndrome do desconforto respiratório, hiperbilirrubinemia e policitemia, prevendo os resultados neonatais a partir de uma análise composta, em vez avaliar cada variável isoladamente. Sendo assim, a predição de desfechos neonatais negativos em gestações complicadas pela DMG pode ser realizada de forma simples e confiável por uma IA, sendo uma ferramenta significativa para o manejo da doença e avaliação prognóstica das pacientes, permitindo uma abordagem mais precisa e personalizada (Houri et al., 2023).

Uma das possíveis consequências da DMG é o aumento do risco de desenvolver DM2 posteriormente, estima-se que mulheres que tiveram DMG apresentam até sete vezes mais chances de desenvolver DM2 em algum momento da vida. Nesse âmbito, novos modelos de IA vêm sendo avaliados para predizer o risco de progressão inicial para DM2 em mulheres com histórico de DMG.

Alguns estudos estão voltados principalmente a modelos de tecnologia IA que utilizam o ML. Uma revisão sistemática que agrupou esses estudos contou com a avaliação dos algoritmos: Regressão Logística (LR), Árvores de Decisão (DT), Naive Bayes (NB), Cox e Random Forest (RF), entre os quais Cox e DT foram os tipos mais utilizados. Como



resultado do estudo, o ML apresentou desempenho favorável com estatística C geral de 0,82 (IC 95%: 0,79 ~ 0,86), sendo adequado quando a estatística C > 0,7. Dentre os diferentes algoritmos, nenhuma diferença significativa de desempenho preditivo foi avaliada; sendo assim, diante dos resultados positivos adquiridos durante o estudo é importante considerar o ML como uma ferramenta preditiva potencial (Zhao et al., 2025).

### **IA no suporte à decisão clínica**

Modelos preditivos baseados em ML vêm sendo desenvolvidos para apoiar decisões clínicas quanto à necessidade de tratamento farmacológico, além da terapia nutricional, em gestantes com DMG. Dentre eles, o modelo mais avançado utilizou o método super learner e apresentou excelente desempenho preditivo, com AUC de 0,934 (IC 95%: 0,931–0,936) no conjunto de descoberta e 0,815 (IC 95%: 0,800–0,829) no conjunto de validação e, semelhantemente, um modelo mais simples e interpretável, baseado em regressão logística, alcançou AUCs de 0,825 (IC 95%: 0,820–0,830) e 0,798 (IC 95%: 0,783–0,813), demonstrando uma redução modesta na capacidade preditiva em comparação ao modelo mais complexo (Liao et al., 2022).

Nesse contexto, os fatores que mais influenciaram a performance dos modelos incluíram a glicemia em jejum no TOTG, a idade gestacional no momento do diagnóstico de DMG e o controle glicêmico durante a primeira semana após o diagnóstico. O estudo evidenciou que a inclusão de dados clínicos coletados tanto antes quanto após o diagnóstico melhora significativamente a capacidade preditiva dos modelos desenvolvidos.

Após a gestação em mulheres com histórico de DMG, é importante manter o monitoramento dos níveis de glicemia. Em 2015, o Instituto Nacional de Excelência em Saúde e Cuidados (NICE) recomendou como triagem um teste de glicemia de jejum de 6 a 13 semanas após o parto ou HbA1c a partir de 13 semanas, também foi orientada a realização da triagem a cada ano. No entanto, a adesão a essa prática foi desafiadora. Nesse contexto, a IA torna-se uma alternativa para identificar mulheres com menor probabilidade de comparecimento ao teste de glicose pós-parto (ppGT), permitindo assim ao profissional de saúde direcionar sua atenção para essas pacientes.

Nesse sentido, Periyathambi et al (2022), em estudo de coorte retrospectivo, avaliaram 607 gestantes que tiveram DMG, utilizando a IA para identificar fatores de riscos que levariam ao não comparecimento das puérperas à triagem pós-natal, com base em parâmetros clínicos coletados rotineiramente durante o pré-natal.

Após a análise dos dados, a IA gerou pontuação de risco individualizada, constatando que mulheres mais jovens, solteiras, multíparas, com IMC elevado e tabagistas tinham mais chances de não comparecerem ao teste pós-parto. Destacou-se que 46% das mulheres avaliadas não compareceriam ao teste pós-parto e 35,1% não realizariam o ppGT. Desse modo, esse método de proporção de risco pode se configurar como uma importante ferramenta para ajudar na identificação dessas mulheres e sensibilizá-las ainda durante o pré-natal ou na alta hospitalar sobre a importância do teste de glicose pós-parto e, se necessário, realizar a busca ativa dessas pacientes (Periyathambi et al., 2022).

### **Aplicativos para o manejo e o tratamento da DMG**

Daley e colaboradores (2021) identificaram aplicativos recentes suportados por IA e sistemas de suporte à decisão clínica. Entre os aplicativos revisados, seis estudos abordaram o MobiGuide, uma ferramenta baseada em diretrizes clínicas digitalizadas para orientação de pacientes e profissionais de saúde. Outros aplicativos incluíram o



SineDie e o GDm-Health, sendo este último o único com validação clínica e aplicação em cenários reais.

A maioria dos aplicativos utilizava IA para análise de dados de saúde e geração de recomendações clínicas. Contudo, observou-se uma frequente confusão entre os conceitos de IA e ML. Aplicativos como o MobiGuide demonstram potencial ao integrar dados clínicos e preferências do paciente para fornecer recomendações mais precisas, mas enfrentam desafios técnicos e regulatórios. A revisão evidenciou a falta de um padrão consolidado para o uso de IA nesses aplicativos, o que compromete a comparabilidade entre os estudos. Além disso, aspectos críticos como segurança de dados e conformidade com regulamentações, como o Regulamento Geral de Proteção de Dados foram pouco explorados, limitando a confiabilidade e a adoção dessas soluções.

Entre as inovações mais promissoras, o DiaCompanion I destaca-se por fornecer previsões em tempo real da glicemia pós-prandial e recomendações personalizadas para evitar hiperglicemia. O desfecho primário avaliado foi a frequência de glicemia pós-prandial acima de 7,0 mmol/L, enquanto os secundários incluíram necessidade de insulinoterapia, HbA1c, número de visitas médicas e satisfação dos pacientes. O modelo proposto permite ajustes dietéticos em tempo real, reduzindo complicações associadas à DMG e minimizando a hiperglicemia pós-prandial.

Além disso, essa tecnologia tem o potencial de reduzir a carga sobre o sistema de saúde, substituindo parte das consultas presenciais por monitoramento remoto e recomendações automáticas. No entanto, desafios como a necessidade de validação clínica mais ampla e a dependência da adesão das gestantes ao uso da ferramenta permanecem como barreiras a serem superadas (Popova et al., 2021).

Outro estudo relevante, conduzido por Kim e colaboradores (2022), investigou a eficácia de um aplicativo de smartphone para intervenções de cuidados de saúde em mães de alto risco. Este fornece intervenções personalizadas, incluindo monitoramento diário de peso, glicemia e pressão arterial por meio de dispositivos Bluetooth, além de notificações sobre dieta, atividade física e saúde mental. O impacto do aplicativo foi avaliado com base na adesão às recomendações, melhora dos indicadores clínicos e redução da necessidade de consultas médicas presenciais.

A tecnologia móvel aplicada à saúde materna demonstra potencial para aprimorar a qualidade do cuidado pré-natal e promover maior autonomia das gestantes no gerenciamento de sua saúde. Estudos indicam que o uso de aplicativos pode reduzir complicações associadas a doenças gestacionais, prevenir eventos adversos e minimizar a necessidade de intervenções médicas emergenciais. Além disso, essas ferramentas facilitam o acompanhamento remoto e permitem intervenções precoces baseadas em dados coletados em tempo real, contribuindo para a redução da sobrecarga do sistema de saúde.

No entanto, a eficácia dessas soluções depende de fatores como adesão das usuárias, usabilidade da plataforma e integração com o atendimento clínico tradicional. Apesar dos avanços, persistem lacunas significativas, como a falta de evidências robustas que comprovem melhorias nos desfechos clínicos em comparação aos métodos convencionais e a insuficiente consideração de fatores interferentes, como nível de escolaridade, acesso à internet e disponibilidade de dispositivos móveis, que podem limitar a efetividade dessas tecnologias na prática clínica (Kim et al., 2022).



## 5. Conclusão

A implementação de meios inovadores de diagnóstico da DMG é fundamental, uma vez que se trata de uma condição prevalente e o método atual, realizado tarde, pode resultar na perda da oportunidade ideal para a intervenção precoce, aumentando, assim, o risco de potenciais complicações materno-fetais.

Frente à análise realizada no presente estudo sobre as formas de rastreamento e a implementação de IA, é possível afirmar que modelos mais atuais, os quais combinam dados clínicos, laboratoriais e epidemiológicos, além de aplicativos de monitoramento, são efetivos e com relevante precisão diagnóstica. Entretanto, há limitações quanto à aplicação em diferentes contextos populacionais e obstáculos técnicos e regulatórios, que possam dificultar a implementação dessas tecnologias no dia a dia dos serviços de saúde.

Além disso, destacam-se lacunas nas bases de dados utilizadas acerca da implementação da IA no cenário brasileiro, sendo fundamentais pesquisas com amostragens locais que considerem a diversidade racial e étnica. Desse modo, poderia minimizar o ônus econômico dos testes universais e dos cuidados de saúde associados à DMG. Logo, a IA pode contribuir no diagnóstico precoce, otimização de recursos e no manejo individualizado da doença.

## Referências

- BERTOLUCI, M. C. et al. **Diagnóstico de diabetes mellitus.** Diretriz Oficial da Sociedade Brasileira de Diabetes, s.d. Disponível em: <https://diretriz.diabetes.org.br/diagnostico-de-diabetes-mellitus/>.
- BIGDELI, S. K. et al. **Predicting gestational diabetes mellitus in the first trimester using machine learning algorithms: A cross-sectional study at a hospital fertility health center in Iran.** *BMC Medical Informatics and Decision Making*, v. 25, n. 1, p. 3, 2025. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC11699820/>.
- CHAN, Y. et al. **A machine learning approach for early prediction of gestational diabetes mellitus using elemental contents in fingernails.** *Scientific Reports*, v. 13, n. 1, p. 1–11, 2023. Disponível em: <https://www.nature.com/articles/s41598-023-31270-0>.
- CUBILLOS, G. et al. **Development of machine learning models to predict gestational diabetes risk in the first half of pregnancy.** *BMC Pregnancy and Childbirth*, v. 23, n. 1, 2023. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC10288662/>.
- DALEY, B. J. et al. **Health apps for gestational diabetes mellitus that provide clinical decision support or artificial intelligence: A scoping review.** *Diabetic Medicine*, v. 39, n. 1, 2021. Disponível em: <https://doi.org/10.1111/dme.14735>.
- FERNANDES, C. E. **Tratado de Obstetrícia Febrasgo.** 1. ed. Rio de Janeiro: Elsevier, 2018.
- GALLARDO-RINCÓN, H. et al. **MIDO GDM: An innovative artificial intelligence-based prediction model for the development of gestational diabetes in Mexican women.** *Scientific Reports*, v. 13, n. 1, 2023. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC10144896/>.
- HOURI, O. et al. **Predicting adverse perinatal outcomes among gestational diabetes complicated pregnancies using neural network algorithm.** *The Journal of Maternal-Fetal & Neonatal Medicine*, v. 36, n. 2, art. 2286928, 2023. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/38044265/>.
- HU, X. et al. **Prediction model for gestational diabetes mellitus using the XGBoost machine learning algorithm.** *Frontiers in Endocrinology*, v. 14, 1105062, 2023. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC10034315/>.



- IQBAL, J. et al. **Reimagining healthcare: Unleashing the power of artificial intelligence in medicine.** *Cureus*, v. 15, n. 9, e44658, 2023. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC10549955/>.
- KANG, B. et al. **Prediction of gestational diabetes mellitus in Asian women using machine learning algorithms.** *Scientific Reports*, v. 13, n. 1, p. 13356, 2023. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC10432552/>.
- KAYA, Y. et al. **The early prediction of gestational diabetes mellitus by machine learning models.** *BMC Pregnancy and Childbirth*, v. 24, n. 1, p. 574, 2024. Disponível em: <https://bmcpregnancychildbirth.biomedcentral.com/articles/10.1186/s12884-024-06783-7>.
- KIM, B. et al. **Effect of smartphone app-based health care intervention for health management of high-risk mothers: A study protocol for a randomized controlled trial.** *Trials*, v. 23, n. 1, 2022. Disponível em: <https://trialsjournal.biomedcentral.com/articles/10.1186/s13063-022-06425-3>.
- KUMAR, M. et al. **Automated machine learning (AutoML)-derived preconception predictive risk model to guide early intervention for gestational diabetes mellitus.** *International Journal of Environmental Research and Public Health*, v. 19, n. 11, p. 6792, 2022. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC9180245/>.
- KUMAR, M. et al. **Population-centric risk prediction modeling for gestational diabetes mellitus: A machine learning approach.** *Diabetes Research and Clinical Practice*, v. 185, p. 109237, 2022. Disponível em: [https://linkinghub.elsevier.com/retrieve/pii/S0168-8227\(22\)00049-3](https://linkinghub.elsevier.com/retrieve/pii/S0168-8227(22)00049-3).
- KURT, B. et al. **Prediction of gestational diabetes using deep learning and Bayesian optimization and traditional machine learning techniques.** *Medical & Biological Engineering & Computing*, v. 61, n. 7, p. 1649–1660, 2023. Disponível em: <https://link.springer.com/article/10.1007/s11517-023-02800-7>.
- LIAO, L. et al. **Development and validation of prediction models for gestational diabetes treatment modality using supervised machine learning: A population-based cohort study.** *BMC Medicine*, v. 20, n. 1, 2022. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC9476287/>.
- MINISTÉRIO DA SAÚDE. **Manual de gestação de alto risco.** Brasília, DF, 2022. Disponível em: [https://bvsms.saude.gov.br/bvs/publicacoes/manual\\_gestacao\\_alto\\_risco.pdf](https://bvsms.saude.gov.br/bvs/publicacoes/manual_gestacao_alto_risco.pdf).
- MAVRELI, D. et al. **Quantitative comparative proteomics reveals candidate biomarkers for the early prediction of gestational diabetes mellitus: A preliminary study.** *In Vivo*, v. 34, n. 2, p. 517–525, 2020. Disponível em: <https://iv.iiarjournals.org/content/34/2/517.long>.
- MCLAREN, R. et al. **A novel and precise profiling tool to predict gestational diabetes.** *Journal of Diabetes Science and Technology*, 2020. Disponível em: <https://journals.sagepub.com/doi/10.1177/1932296820948883>.
- PERIYATHAMBI, N. et al. **Machine learning prediction of non-attendance to postpartum glucose screening and subsequent risk of type 2 diabetes following gestational diabetes.** *PLOS ONE*, v. 17, n. 3, e0264648, 2022. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC8901061/>.
- POPOVA, P. et al. **Perinatal health predictors using artificial intelligence: A review.** *Women's Health*, v. 17, 2021. Disponível em: <https://journals.sagepub.com/doi/10.1177/17455065211046132>.
- SANTOS, C. M. C.; PIMENTA, C. A. M.; NOBRE, M. R. C. **A estratégia PICO para a construção da pergunta de pesquisa e busca de evidências.** *Revista Latino-Americana de*



*Enfermagem*, v. 15, n. 3, p. 508–511, 2007. Disponível em:  
[http://www.scielo.br/pdf/rlae/v15n3/pt\\_v15n3a23.pdf](http://www.scielo.br/pdf/rlae/v15n3/pt_v15n3a23.pdf).

**SHEN, J. et al.** **An innovative artificial intelligence-based app for the diagnosis of gestational diabetes mellitus (GDM-AI): Development study.** *Journal of Medical Internet Research*, v. 22, n. 9, e21573, 2020. Disponível em:  
<https://www.jmir.org/2020/9/e21573>.

**SILVA, G. A.; SOUZA, C. L.; OLIVEIRA, M. V.** **Teste oral de tolerância à glicose: solicitações desnecessárias e condições adequadas à realização do teste.** *Jornal Brasileiro de Patologia e Medicina Laboratorial*, v. 56, 2020. Disponível em:  
<https://www.scielo.br/j/jbpml/a/XkYsh8gcTFGhLB6jwGMjVnk/>.

**WANG, J. et al.** **An early model to predict the risk of gestational diabetes mellitus in the absence of blood examination indexes: Application in primary health care centres.** *BMC Pregnancy and Childbirth*, v. 21, n. 1, 2021. Disponível em:  
<https://pmc.ncbi.nlm.nih.gov/articles/PMC8653559/>.

**WU, Y.-T. et al.** **Early prediction of gestational diabetes mellitus in the Chinese population via advanced machine learning.** *The Journal of Clinical Endocrinology and Metabolism*, v. 106, n. 3, p. e1191–e1205, 2021. Disponível em:  
<https://academic.oup.com/jcem/article/106/3/e1191/6031346>.

**XING, J. et al.** **Enhancing gestational diabetes mellitus risk assessment and treatment through GDMPredictor: A machine learning approach.** *Journal of Endocrinological Investigation*, v. 47, n. 9, p. 2351–2360, 2024. Disponível em:  
<https://link.springer.com/article/10.1007/s40618-024-02328-z>.

**YE, Y. et al.** **Comparison of machine learning methods and conventional logistic regressions for predicting gestational diabetes using routine clinical data: A retrospective cohort study.** *Journal of Diabetes Research*, v. 2020, p. 1–10, 2020. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1155/2020/4168340>.

**ZENATTI, G. T. et al.** **Diabetes gestacional: prevalência e fatores de risco – revisão.** *Archives of Health*, v. 5, n. 3, p. 1–6, 2024. Disponível em:  
<https://ojs.latinamericanpublicacoes.com.br/ojs/index.php/ah/article/view/1850/1600>.

**ZHANG, J.; WANG, F.** **Prediction of gestational diabetes mellitus under cascade and ensemble learning algorithm.** *Computational Intelligence and Neuroscience*, v. 2022, p. 3212738, 2022. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC9303101/>.

**ZHAO, M. et al.** **Predictive value of machine learning for the progression of gestational diabetes mellitus to type 2 diabetes: A systematic review and meta-analysis.** *BMC Medical Informatics and Decision Making*, v. 25, n. 1, 2025. Disponível em:  
<https://pmc.ncbi.nlm.nih.gov/articles/PMC11727323/>.