



Métodos de inteligência artificial na predição e diagnóstico precoces de complicações na gravidez

Artificial intelligence methods in the prediction and early diagnosis of pregnancy complications

Métodos de inteligencia artificial en la predicción y diagnóstico precoz de las complicaciones del embarazo

Carina Gleice Tabosa Quixabeira¹, Maria da Conceição Nascimento Gomes², Isabela Oliveira da Silva Flor², Andreza Pereira dos Santos², Amanda Aline dos Santos de Almeida Batista², Chrystianne da Silva Oliveira³, José William Araújo do Nascimento⁴.

RESUMO

Objetivo: Analisar e sintetizar as evidências científicas disponíveis na literatura sobre os métodos de inteligência artificial (IA) na predição e diagnóstico precoces de complicações na gravidez. **Métodos:** Trata-se de uma revisão integrativa, realizada nas bases de dados EMBASE, PubMed, Scopus e Web of Science, por meio dos seguintes descritores: “Artificial Intelligence”, “Machine Learning”, “Deep Learning”, “Pregnancy Complications”, “perinatal complications” e “Postpartum”. Foram incluídos estudos publicados entre 2019 a 2023 que utilizam métodos de IA para prever complicações na gravidez. **Resultados:** A amostra final consistiu em 13 artigos, com uma concentração mais elevada de publicações nos anos de 2019 e 2020. A maioria dos estudos foi conduzida na China, e os designs de pesquisa predominantes foram estudos de coorte. Os modelos de IA utilizados mostraram eficácia na predição de complicações como pré-eclâmpsia, diabetes mellitus gestacional, nascimento prematuro e invasão placentária, utilizando dados de prontuários eletrônicos e outros biomarcadores. **Considerações finais:** Esta revisão evidencia o impacto significativo dos modelos de IA na melhoria da predição e diagnóstico de complicações na gravidez. Os resultados sublinham a necessidade de integração contínua dessas tecnologias na prática clínica obstétrica, bem como de pesquisas futuras para validar e expandir sua aplicabilidade em diferentes contextos clínicos.

Palavras-chave: Complicações na gravidez, Inteligência artificial, Obstetria.

ABSTRACT

Objective: To analyze and synthesize the scientific evidence available in the literature on the methods of artificial intelligence (AI) in the early prediction and diagnosis of pregnancy complications. **Methods:** This is an integrative review, conducted on the EMBASE, PubMed, Scopus, and Web of Science databases, using the following descriptors: “Artificial Intelligence”, “Machine Learning”, “Deep Learning”, “Pregnancy Complications”, “perinatal complications” and “Postpartum”. Studies published between 2019 and 2023 that use AI methods to predict pregnancy complications were included. **Results:** The final sample consisted of 13 articles, with a higher concentration of publications in the years 2019 and 2020. Most studies were conducted in China, and the predominant research designs were cohort studies. The AI models used were effective in

¹ Universidade Federal de Pernambuco (UFPE) – Departamento de Enfermagem, Recife - PE.

² Universidade Católica de Pernambuco (UNICAP), Recife - PE.

³ Universidade do Estado do Amazonas (UEA), Manaus - AM.

⁴ Centro de Informática da Universidade Federal de Pernambuco (Cin-UFPE), Recife - PE.

predicting complications such as preeclampsia, gestational diabetes mellitus, premature birth, and placental invasion, using electronic medical records and other biomarkers. **Final considerations:** This review highlights the significant impact of AI models in improving the prediction and diagnosis of pregnancy complications. The results underline the need for continuous integration of these technologies in obstetric clinical practice, as well as future research to validate and expand their applicability in different clinical contexts.

Keywords: Pregnancy complications, Artificial intelligence, Obstetrics.

RESUMEN

Objetivo: Analizar y sintetizar la evidencia científica disponible en la literatura sobre los métodos de inteligencia artificial (IA) en la predicción y diagnóstico tempranos de complicaciones en el embarazo. **Métodos:** Se trata de una revisión integrativa, realizada en las bases de datos EMBASE, PubMed, Scopus y Web of Science, utilizando los siguientes descriptores: “Artificial Intelligence”, “Machine Learning”, “Deep Learning”, “Pregnancy Complications”, “perinatal complications” y “Postpartum”. Se incluyeron estudios publicados entre 2019 y 2023 que utilizan métodos de IA para predecir complicaciones en el embarazo. **Resultados:** La muestra final consistió en 13 artículos, con una mayor concentración de publicaciones en los años 2019 y 2020. La mayoría de los estudios se realizaron en China, y los diseños de investigación predominantes fueron estudios de cohortes. Los modelos de IA utilizados demostraron eficacia en la predicción de complicaciones como preeclampsia, diabetes mellitus gestacional, parto prematuro e invasión placentaria, utilizando registros médicos electrónicos y otros biomarcadores. **Consideraciones finales:** Esta revisión evidencia el impacto significativo de los modelos de IA en la mejora de la predicción y diagnóstico de complicaciones en el embarazo. Los resultados subrayan la necesidad de integrar continuamente estas tecnologías en la práctica clínica obstétrica, así como de investigaciones futuras para validar y expandir su aplicabilidad en diferentes contextos clínicos.

Palabras clave: Complicaciones del embarazo, Inteligencia artificial, Obstetricia.

INTRODUÇÃO

A gravidez, um estado fisiológico complexo, implica riscos significativos para a saúde materna, apesar da percepção comum de normalidade.

Relatórios da Organização Mundial da Saúde (OMS) de 2019 indicam que aproximadamente 15% das mulheres grávidas enfrentam complicações sérias que exigem intervenção médica especializada, incluindo procedimentos obstétricos críticos para assegurar a sobrevivência tanto da mãe quanto do feto (WHO, 2019).

A magnitude do problema de mortalidade materna é evidenciada pelos dados que apontam para a ocorrência de cerca de 800 mortes diárias relacionadas a complicações evitáveis da gravidez. Em 2017, registrou-se um total aproximado de 295.000 mortes maternas, com uma prevalência desproporcional de 94% desses casos em regiões de baixos recursos, sublinhando disparidades globais significativas no acesso e na qualidade do atendimento à saúde materna (WHO, 2019).

Essa realidade reforça a necessidade crítica de estratégias de saúde pública efetivas para enfrentar não apenas as complicações conhecidas, mas também as situações de risco que podem surgir em gravidezes consideradas de baixo risco. A ênfase da OMS nos cuidados intraparto baseados em evidências para todas as mulheres independentemente do contexto de saúde, destaca a importância de desenvolver políticas de saúde robustas e protocolos clínicos adaptados a diferentes realidades. Isso inclui a promoção de cuidados de saúde materna acessíveis e de alta qualidade como meio essencial para reduzir a mortalidade materna (WHO, 2018; HINKLE SN, et al., 2023).

Além disso, as complicações obstétricas específicas, como hemorragia, ruptura uterina e distúrbios hipertensivos, são identificadas como causas importantes de mortalidade e morbidade materna, sobretudo em contextos em que há limitação no acesso a cuidados especializados. A identificação precoce e o manejo adequado dessas condições são aspectos vitais para a saúde materna.

Paralelamente, fatores como obesidade, diabetes gestacional e idade avançada da mãe contribuem para o aumento do risco de complicações perinatais (MARIONA FG, 2016; EDWARDS P, et al., 2020).

Diante deste contexto, a inteligência artificial (IA) emerge como uma ferramenta promissora na medicina, oferecendo novas perspectivas para a predição e diagnóstico precoces de complicações na gravidez. A IA, um campo interdisciplinar que combina ciência da computação, engenharia e dados massivos, propõe soluções inovadoras para o processamento e análise de informações de saúde (RAHMAN A, et al., 2024).

Especificamente, o aprendizado de máquina, um subcampo da IA, mostra grande potencial ao permitir que algoritmos computacionais aprendam com experiências e dados, melhorando a capacidade de identificar padrões complexos e prever desfechos clínicos com mínima intervenção humana (AHMED Z, et al., 2020; PAPPADA SM, 2021). Ao analisar dados variados, que vão desde registros eletrônicos de saúde até parâmetros bioquímicos, estas tecnologias fornecem contribuições valiosas para o manejo de pacientes grávidas, especialmente naqueles casos de alto risco (DHOMBRES F, et al., 2022).

Contudo, a adoção da IA na saúde materna não está livre de desafios. A maioria dos sistemas de apoio à decisão baseados em IA continua sendo percebida como “caixas pretas”, onde a lógica interna e os processos de tomada de decisão não são transparentes para as equipes clínicas. Esta falta de interpretabilidade pode limitar a confiança e a integração desses sistemas nos cuidados de saúde. Reconhecendo essa barreira, pesquisadores têm se dedicado ao desenvolvimento de modelos de IA mais interpretáveis e métodos explicativos, visando facilitar a compreensão e aceitação clínica dessas ferramentas (CARVALHO DV, et al., 2019).

Apesar dos desafios, estudos recentes têm demonstrado o envolvimento crescente da IA em áreas como ginecologia e obstetrícia (IFTIKHAR PM, et al., 2020; CECULA P, 2021). Esta tendência crescente justifica a necessidade de explorar mais a fundo o potencial da IA na assistência obstétrica, especialmente na identificação e gestão de complicações na gravidez. A relevância desta investigação reside na possibilidade de transformar a prática clínica, oferecendo ferramentas mais precisas e eficientes para o acompanhamento da saúde materna e fetal. Assim, este estudo tem como objetivo analisar e sintetizar as evidências científicas disponíveis na literatura sobre os métodos de IA na predição e diagnóstico precoces de complicações na gravidez.

MÉTODOS

O método de síntese do conhecimento selecionado para a condução deste estudo foi a revisão integrativa da literatura, uma abordagem abrangente que facilita a síntese de evidências a partir de pesquisas primárias e enriquece a compreensão sobre tópicos específicos. A eficácia da revisão integrativa reside em sua habilidade de oferecer uma perspectiva holística sobre o tema em estudo, iluminando aspectos ainda inexplorados e criando um alicerce robusto para futuras investigações e práticas orientadas por evidências científicas (PEREIRA AS, et al., 2018).

Para a realização desta revisão, foi adotado um procedimento metodológico rigoroso, estruturado nas seguintes fases: 1) Definição da questão de pesquisa orientadora e dos objetivos específicos da revisão; 2) Determinação dos critérios para seleção dos estudos incluídos; 3) Execução de uma busca sistemática em bases de dados e fontes bibliográficas pertinentes; 4) Seleção, avaliação e síntese das informações coletadas; 5) Análise e interpretação dos resultados encontrados; 6) Elaboração e discussão das conclusões derivadas dos dados (WHITTEMORE R, et al., 2005).

Para a condução desta revisão integrativa, adotou-se a estrutura PICOC como guia metodológico. “P” (População) refere-se a mulheres grávidas, com ênfase naquelas que apresentam riscos elevados de complicações. “I” (Intervenção) relaciona-se com a aplicação de métodos de IA incluindo algoritmos de aprendizado de máquina, na predição e diagnóstico de complicações na gravidez. “C” (Comparação) não se aplica diretamente neste estudo. “O” (Outcomes) abrange os resultados relacionados à acurácia, eficácia e impacto desses métodos de IA na identificação precoce de complicações, bem como suas implicações para a saúde materna e fetal. Referente ao “C” (Contexto), investiga os contextos clínicos e de saúde em que essas tecnologias de IA são implementadas, observando as particularidades e desafios no manejo da saúde de gestantes de alto risco.

Com base nessa estruturação, a pergunta de pesquisa central foi definida como: “Quais as evidências científicas dos métodos de IA na predição e diagnóstico precoces de complicações na gravidez?”. Assim, os critérios de elegibilidade para o desenvolvimento desta revisão foram: estudos originais sem restrição de idioma, com acesso ao texto completo; estudos baseados em humanos publicados entre 2019 e 2023; pesquisas que utilizam métodos de IA para prever complicações na gravidez; complicações durante a gravidez e a termo na mãe e no recém-nascido.

Diante do exposto, foram excluídos estudos que incluíssem complicações pós-parto, doença congênita materna que aumenta o risco de complicações perinatais e doenças congênitas fetais. Destaca-se ainda que também foram excluídos da amostra estudos duplicados nas bases de dados, revisões de literatura (narrativas, scoping, integrativas, sistemáticas e meta-análises), artigos editoriais, opiniões, dissertações, teses e qualquer publicação que não estivesse diretamente alinhada com o propósito primordial desta investigação.

Para a busca dos estudos primários foram selecionadas quatro bases de dados, relevantes para a área da médica, a saber: National Institute of Medicine (NIH-PubMed), EMBASE, Scopus e Web of Science. O levantamento abrangeu os meses de dezembro de 2023 a janeiro de 2024.

Os quatro componentes descritos da sigla PICOC foram utilizados em diferentes combinações de descritores controlados, empregando-se termos específicos derivados do Medical Subject Headings (MeSH). Os descritores adotados foram: “Artificial Intelligence”, “Machine Learning”, “Deep Learning”, “Pregnancy Complications”, “perinatal complications” e “Postpartum”. Para aprimorar e detalhar a estratégia de busca, foi fundamental a utilização dos operadores booleanos "AND", "OR" e NOT. A aplicação desses descritores foi cuidadosamente ajustada para corresponder às características de cada base de dados utilizada, garantindo assim uma cobertura abrangente e específica. Os detalhes dessas combinações estão ilustrados no (Quadro 1).

Quadro 1 - Estratégias de busca nas bases de dados.

Base de dados (artigos recuperados)	Estratégia de busca
PubMed (597)	(((("Artificial Intelligence") OR ("Machine Learning") AND ("Pregnancy Complications") OR ("perinatal complications") NOT ("Postpartum"))
Scopus (224)	(((("Artificial Intelligence") OR ("Machine Learning") OR ("Deep Learning") AND ("Pregnancy Complications") NOT ("Postpartum"))
Web of Science (87)	(((("Artificial Intelligence") OR ("Machine Learning") AND ("Pregnancy Complications") NOT ("Postpartum"))
Embase (54)	(((("Machine Learning ") OR ("Deep Learning") AND ("Pregnancy Complications") NOT ("Postpartum"))

Fonte: Quixabeira CGT, et al., 2024.

A seleção dos estudos foi realizada por avaliadores independentes seguindo as estratégias delineadas. Estes especialistas inicialmente examinaram os títulos e resumos para uma triagem preliminar, registrando suas escolhas em uma planilha de avaliação.

A comparação das seleções individuais revelou um coeficiente Kappa de 0,89, refletindo uma alta consistência na escolha dos estudos e indicando um processo de seleção sistemático e confiável (MCHUGH ML, 2012).

Discordâncias na escolha dos artigos foram resolvidas por meio de discussões conjuntas até se chegar a um consenso. Os estudos finais selecionados foram então organizados e gerenciados utilizando o software de referência bibliográfica EndNote online (versão XII - Desktop) (MENDES KDS, et al., 2019).

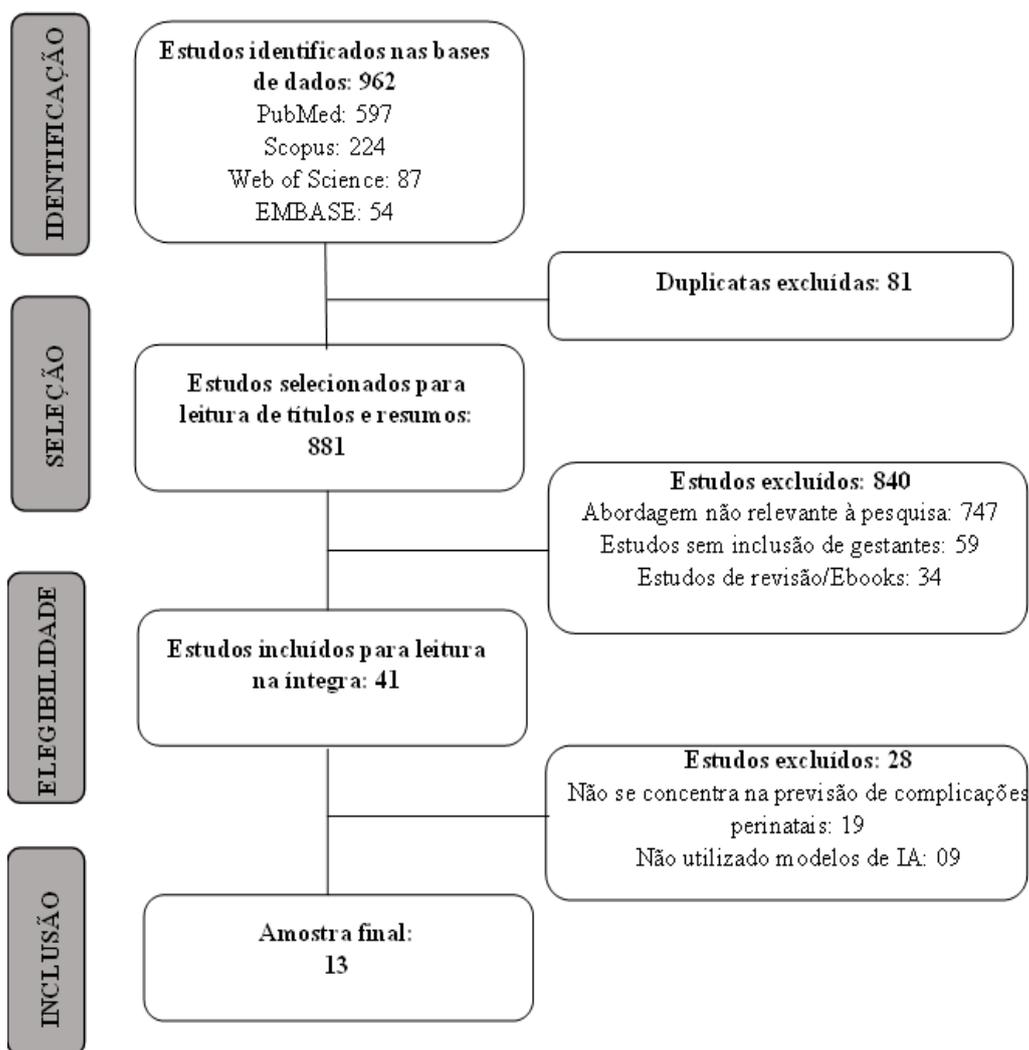
Para assegurar uma coleta e análise exaustiva de dados pertinentes, foi implementado um processo estruturado de agregação de informações. Os critérios definidos para a seleção dos artigos envolveram: identificação do estudo (título, autores, revista, ano de publicação, país de origem do estudo, classificação de

impacto de acordo com o Journal Citation Reports – JCR, posição no ranking Qualis Capes 2017-2020, e a base de dados onde o estudo foi localizado), características metodológicas do estudo (tipo de estudo, nível de evidência), detalhamento das tecnologias de IA aplicadas, resultados primários observados e desafios identificados.

Durante a pesquisa inicial nas bases de dados designadas, foram identificados 962 artigos científicos. Desses, 81 estavam duplicados e foram considerados apenas uma vez, resultando em 881 artigos para uma avaliação inicial baseada em títulos e resumos. Após essa análise preliminar, 747 artigos foram excluídos por não corresponderem estritamente ao tema central da pesquisa. Além disso, 59 estudos foram excluídos por abordarem outras populações investigadas que não seja a de gestantes, e 34 artigos não entraram na análise da próxima etapa por serem caracterizados como de revisão.

Dessa seleção, 41 publicações foram submetidas a uma avaliação mais aprofundada do texto integral. Entretanto, deste grupo, 19 foram descartados por preverem complicações pós-natais e 09 por não se concentrarem especificamente em métodos de IA para a predição e diagnóstico de complicações na gravidez. Portanto, um total de 13 artigos foi definitivamente incluído nesta revisão integrativa. O processo de seleção e exclusão dos artigos é detalhado no fluxograma desenvolvido conforme as diretrizes do Preferred Reporting Items for Systematic reviews and Meta-Analyses (PRISMA), apresentado na (Figura 1).

Figura 1 - Fluxograma do processo de seleção dos estudos.



Fonte: Quixabeira CGT, et al., 2024.

A meticulosa seleção dos estudos para esta revisão foi baseada no respeitado sistema de Hierarquia de Evidências de Stillwell S, et al. (2010). Esta hierarquia é essencial para avaliar a força e a confiabilidade dos estudos, constituindo um elemento chave na asseguarção da qualidade e pertinência dos resultados para aplicações clínicas e acadêmicas.

Conforme este modelo, os níveis mais altos de evidência, I e II, incluem estudos com forte fundamentação metodológica, como ensaios clínicos controlados randomizados e meta-análises de pesquisas rigorosas. Estas fontes são de extrema importância para embasar práticas clínicas que se fundamentam em evidências sólidas. Por outro lado, os níveis III e IV, compreendendo estudos observacionais como coortes e casos-controles, ainda que ofereçam informações valiosas, podem apresentar variáveis menos controladas, o que introduz um certo grau de variabilidade nas conclusões (STILLWELL S, et al., 2010).

Os níveis inferiores, V a VII, incluem evidências mais básicas, geralmente oriundas de estudos de caso, opiniões de especialistas ou pesquisas descritivas. Apesar de seu valor para preencher lacunas na literatura científica, estas fontes devem ser cuidadosamente analisadas e confrontadas com evidências mais robustas quando utilizadas para formular diretrizes clínicas (STILLWELL S, et al., 2010).

Adicionalmente, neste estudo, a observância rigorosa das normas éticas foi uma prioridade. Esforços foram dedicados para assegurar o reconhecimento adequado a todos os autores dos artigos analisados, em conformidade com os padrões internacionais de direitos autorais e boas práticas em pesquisa (BRASIL, 1998).

RESULTADOS

Foram selecionados 13 estudos para compor a amostra final desta revisão, conforme ilustrado no **Quadro 2**. A análise dos dados revela que os anos de 2019 e 2020 foram os mais produtivos, cada um com quatro publicações. A China se destacou como o país com maior número de contribuições (n: 05), seguida pelos Estados Unidos (n: 02). No que tange à qualidade dos periódicos em que os estudos foram publicados, a maioria se enquadra na classificação entre A1 e A3 segundo a CAPES, com destaque para o periódico "Nature Medicine", que apresentou o mais elevado fator de impacto (87.244). Quanto à metodologia dos estudos, predominaram pesquisas com design de coorte, conferindo um nível de evidência III, enquanto outros estudos apresentaram designs retrospectivos e ensaios clínicos não randomizados, com níveis de evidência variando de III a IV.

Quadro 2 - Caracterização geral dos artigos da amostra final.

ID	Autoria/ ano	País	Periódico (Qualis – JCR)	Design do estudo (NE*)	Objetivos
01	Jhee JH, et al. (2019)	Coreia do Sul	PLoS One (A1 - 3.752)	Ensaio clínico não randomizado (III)	Desenvolver modelos usando aprendizado de máquina para prever pré-eclâmpsia de início tardio usando dados de prontuários eletrônicos hospitalares.
02	Rittenhou se KJ, et al. (2019)	Zâmbia	PLoS One (A1 - 3.752)	Coorte (III)	Utilizar algoritmos de IA para identificação de recém-nascidos prematurados.
03	Khatibi T, et al. (2019)	Irã	Archives of Gynecology and Obstetrics (A2 - 2.493)	Coorte (III)	Propor métodos para previsão de nascimento prematuro iniciado pelo provedor e partos prematuros espontâneos e classificar as características preditivas.
04	Gao C, et al. (2019)	EUA	Studies in Health Technology and	Coorte (III)	Identificar morbidade maternal grave a partir de registros eletrônicos de saúde.

			Informatics (A2 – 0.285)		
05	Sun H, et al. (2019)	China	European Radiology (A1 – 5.9)	Retrospectivo (IV)	Investigar se as características da textura intraplacentária da ressonância magnética placentária de rotina podem prever de forma objetiva e precisa a placentação invasiva.
06	Malacova E, et al. (2020)	Austrália	Scientific Report (A1 – 4.997)	Coorte (III)	Quantificar e validar a precisão preditiva de uma gama abrangente de fatores de risco coletados rotineiramente para prever natimortos.
07	Guo Z, et al. (2020)	China	Advanced Science (A1 – 17.521)	Retrospectivo (IV)	Analisar a precisão preditiva de complicações na gestação a partir do perfil do promotor do genoma completo do DNA plasmático.
08	Artzi NS, et al. (2020)	Israel	Nature Medicine (A1 – 87.244)	Coorte (III)	Analisar a precisão preditiva de diabetes mellitus gestacional com base em registros eletrônicos de saúde nacionais.
09	Li YX, et al. (2021)	China	Pregnancy Hypertension (A4 – 2.494)	Coorte (III)	Prever o risco de pré-eclâmpsia em mulheres usando algoritmos de IA, com base em registros eletrônicos de saúde coletados no início do segundo trimestre.
10	Liu M, et al. (2022)	China	Frontiers in Physiology (A2 – 4.755)	Coorte (III)	Utilizar métodos de IA para analisar dados clínicos e laboratoriais disponíveis obtidos durante a triagem pré-natal no início da gravidez para desenvolver modelos preditivos em pré-eclâmpsia.
11	Zhang H, et al. (2023)	China	Frontiers in Endocrinology (A3 – 6.055)	Coorte (III)	Desenvolver um nomograma simples de usar baseado em múltiplos fatores de risco comuns de registros médicos eletrônicos de saúde,
12	Watanabe M, et al. (2023)	Japão	Scientific Report (A1 – 4.997)	Coorte (III)	Analisar a previsão de diabetes mellitus gestacional usando a IA a partir de registros médicos.
13	Cersonsky TEK, et al. (2023)	Islândia	American Journal of Obstetrics & Gynecology (10.693)	Coorte (III)	Criar e refinar modelos de IA para prever natimortos usando dados disponíveis antes da viabilidade (22-24 semanas).

Nota: NE* - Nível de evidência.

Fonte: Quixabeira CGT, et al., 2024.

Conforme demonstrado no **Quadro 3**, esta revisão integra e consolida informações significativas dos estudos selecionados sobre o uso de modelos de IA na predição de complicações na gravidez.

A amostra total abrange uma extensa coorte de 3.252.295 gestantes, indicando a abrangência e a relevância dos dados analisados. A maioria dos estudos (n: 11) empregou prontuários eletrônicos na construção de modelos de IA, enquanto um estudo utilizou imagens médicas e outro se baseou em marcadores biológicos, refletindo a diversidade nas abordagens metodológicas.

Os modelos de IA foram primordialmente aplicados para prever complicações como pré-eclâmpsia, nascimento prematuro, diabetes mellitus gestacional e invasão placentária.

Os resultados gerais dos modelos indicam benefícios substanciais, com taxas elevadas de precisão e acurácia na predição de complicações. Os modelos de IA alcançaram áreas sob a curva de recepção operacional (auROC) superiores a 0,90, evidenciando sua eficácia na identificação precoce de riscos.

Estes achados sugerem que a implementação de modelos de IA pode melhorar significativamente a tomada de decisão clínica e o manejo de gestações de alto risco, potencializando a prevenção e a intervenção precoce em complicações perinatais. Os estudos também revelaram a capacidade dos modelos de IA de integrar e analisar diversas variáveis clínicas e laboratoriais, demonstrando o potencial da tecnologia em oferecer uma abordagem mais personalizada e precisa no acompanhamento da saúde materna e fetal (**Quadro 3**).

Quadro 3 – Modelos de Inteligência Artificial e seus resultados na predição de complicações na gravidez.

ID	N (gestantes)	Modelos de IA utilizados	Principais resultados
01	11.006	Modelos utilizando prontuários eletrônicos: Regressão logística, árvores de decisão, Naive Bayes, Support Vector Machine, Random-Forest e Descida gradiente estocástica.	O uso combinado de fatores maternos e dados laboratoriais pré-natais comuns do início do segundo trimestre até o início do terceiro trimestre poderia prever com eficácia a pré-eclâmpsia de início tardio usando algoritmos de IA.
02	1.450	Modelos utilizando prontuários eletrônicos: Regressão logística binária, Random-Forest e generalized additive model.	Identificou-se uma combinação de seis parâmetros acessíveis (DUM, peso ao nascer, parto de gêmeos, altura materna, hipertensão no trabalho de parto e status sorológico do HIV) que podem ser usados para superar os métodos atuais de previsão de IG. Para a previsão de nascimento prematuro, esta combinação de covariáveis classificou corretamente >94% dos recém-nascidos e alcançou uma área sob a curva (AUC) de 0,9796.
03	1.547.677	Modelos utilizando prontuários eletrônicos: árvores de decisão, Support Vector Machine e Random-Forest.	Os resultados experimentais mostram que o melhor desempenho dos modelos propostos para predição de nascimento prematuro é acurácia de 81% e área sob a curva característica de operação do receptor (AUC) de 68%.
04	45.858	Modelos utilizando prontuários eletrônicos: regressão logística.	A estrutura superou um modelo de última geração dos CDC EUA (AUC de 0,94 vs. 0,80). No processo, revelou-se vários novos indicadores de morbidade materna grave, incluindo distúrbios de fluidos ou eletrólitos, síndrome de resposta inflamatória sistêmica e acidose.
05	155	Modelos utilizando imagens médicas: generalized additive model.	Desempenho ideal com sensibilidade, especificidade, precisão e área sob a curva ROC (AUC) de 100%, 88,5%, 95,2% e 0,98 na predição de invasão placentária. O modelo pode prever com precisão a invasão placentária e facilitar a tomada de decisão clínica para mulheres grávidas com suspeita de invasão placentária.
06	952.813	Modelos utilizando prontuários eletrônicos: redes neurais artificiais.	O classificador de melhor desempenho (XGBoost) previu 45% de natimortos para todas as mulheres e 45% de natimortos após a inclusão do histórico de gravidez anterior. Quase metade dos nados-mortos poderia ser potencialmente identificada no pré-natal com base numa combinação de complicações atuais da gravidez, anomalias congênitas, características maternas e história médica.

07	2.199	Modelos utilizando marcadores biológicos: regressão logística	As complicações na gravidez foram previstas com sucesso com uma precisão de 80,3% para macrosomia, 78,9% para crescimento fetal, 72,1% para diabetes mellitus gestacional e 83,0% pré-eclâmpsia. Os resultados sugerem que o perfil do promotor do cfDNA pode ser usado como um biomarcador biológico para prever complicações na gravidez no início da idade gestacional.
08	588.622	Modelos utilizando prontuários eletrônicos: Gradient Boosting Machines.	Os modelos predizem a diabetes mellitus gestacional com alta precisão mesmo no início da gravidez (área sob a curva operacional do receptor (auROC) = 0,85). Eles podem permitir uma intervenção em estágio inicial em mulheres de alto risco, bem como uma abordagem de triagem econômica que poderia evitar a necessidade de testes de tolerância à glicose, identificando mulheres de baixo risco.
09	3.759	Modelos utilizando prontuários eletrônicos: regressão logística, Support Vector Machine, Random-Forest e reforço de gradiente extremo (XGBoost).	A característica mais preditiva do desenvolvimento de pré-eclâmpsia foi a glicemia plasmática em jejum, seguida pela pressão arterial média e índice de massa corporal. Um modelo fácil de usar que um paciente poderia responder de forma independente ainda permitiu uma previsão precisa, com auROC de 0,83.
10	11.152	Modelos utilizando prontuários eletrônicos: rede neural profunda, regressão logística, árvore de decisão, Support Vector Machine e Random-Forest.	O método de IA neste estudo identificou automaticamente um conjunto de características preditivas importantes e produziu alto desempenho preditivo sobre o risco de pré-eclâmpsia a partir de informações no início da gravidez.
11	924	Modelos utilizando prontuários eletrônicos: regressão logística multivariada.	A sensibilidade, especificidade, valor preditivo positivo, valor preditivo negativo e índice de Youden do nomograma foram 70,21%, 70,54%, 44,84%, 87,41% e 0,4075, respectivamente. Ao integrar vários fatores de risco comuns dos EMHRs, este estudo desenvolveu um nomograma simples de usar para prever o diabetes mellitus gestacional no início da gravidez.
12	82.698	Modelos utilizando prontuários eletrônicos: árvores de decisão, Support Vector Machine e Random-Forest.	Os resultados mostraram alta precisão, interpretabilidade e superioridade para prever o diabetes mellitus gestacional usando dados de coorte de nascimentos.
13	3.982	Modelos utilizando prontuários eletrônicos: Random-Forest.	A aplicação de técnicas avançadas de aprendizado de máquina a um banco de dados abrangente de natimortos e nascidos vivos com variáveis únicas e clinicamente relevantes resultou em um algoritmo que poderia identificar com precisão 85% das gestações que resultariam em natimortos, antes de atingirem a viabilidade.

Fonte: Quixabeira CGT, et al., 2024.

DISCUSSÃO

Esta revisão concentrou-se na análise da eficácia dos modelos de IA na predição e diagnóstico precoces de complicações na gravidez. Dada a complexidade e a criticidade da saúde materno-fetal, a implementação de tecnologias avançadas na prática obstétrica surge como uma abordagem inovadora e promissora. As complicações na gravidez, como pré-eclâmpsia, diabetes gestacional e nascimento prematuro, têm implicações significativas tanto para a mãe quanto para o feto, enfatizando a necessidade de ferramentas de diagnóstico precisas e eficazes.

Tradicionalmente, o diagnóstico dessas condições depende da interpretação clínica de sinais e sintomas, muitas vezes sujeitos a variabilidade. No entanto, os resultados desta revisão indicam que os modelos de IA podem melhorar substancialmente a precisão da predição dessas complicações (SUFRIYANA H, et al., 2020).

À luz dos resultados apresentados, os modelos de IA abordados nos estudos selecionados apresentam uma gama variada de aplicações, refletindo a versatilidade e o potencial inovador desta tecnologia na obstetrícia. Estes modelos foram desenvolvidos com o objetivo de aprimorar a predição e o diagnóstico de complicações críticas na gravidez, tais como pré-eclâmpsia, nascimento prematuro, diabetes mellitus gestacional e invasão placentária.

No contexto da pré-eclâmpsia, quatro estudos de diferentes localizações geográficas abordaram ensaios com uso de IA para predição desta complicação (JHEE JH, et al., 2019; GUO Z, et al., 2020; LI YX, et al., 2021; LIU M, et al., 2022). Esta condição, caracterizada por hipertensão e riscos potenciais para mãe e feto, mostrou-se um campo fértil para a aplicação de modelos de IA.

Os modelos desenvolvidos demonstraram alta capacidade de integração e análise de variáveis clínicas e biomarcadores, alcançando uma precisão notável. Isso representa um avanço significativo em comparação aos métodos tradicionais de diagnóstico, oferecendo uma abordagem mais eficaz e precoce na identificação de gestantes em risco de desenvolver pré-eclâmpsia (LI YX, et al., 2021; LIU M, et al., 2022).

Destaca-se que o desenvolvimento de métodos simples de predição de pré-eclâmpsia tem sido uma tarefa complexa. Uma das principais razões para esta dificuldade é que a patogênese da pré-eclâmpsia é complexa e envolve vários fatores. No entanto, inúmeras tentativas foram feitas para prever com precisão a pré-eclâmpsia, o que permitiria a detecção e o tratamento precoces. A abordagem mais comum para aumentar a previsibilidade da doença tem sido identificar fatores de risco (SIRCAR M, et al., 2015).

Os parâmetros tradicionalmente relatados como relacionados ao desenvolvimento de pré-eclâmpsia são história prévia de pré-eclâmpsia, doença renal crônica conhecida, hipertensão, diabetes, distúrbios autoimunes, como lúpus eritematoso sistêmico e síndrome antifosfolípide, idade materna avançada (> 40 anos) e um corpo índice de massa superior a 35 kg/m² foram associados a um risco aumentado de desenvolvimento de pré-eclâmpsia. Vários novos fatores, como Doppler e indicadores bioquímicos, também são identificados como um dos fatores mais importantes associados ao desenvolvimento de pré-eclâmpsia (POON LC, et al., 2014; SHARMA DD, et al., 2024).

Nos estudos contemporâneos, como em uma revisão sistemática recente, observa-se uma prevalência do uso de algoritmos de regressão logística múltipla para estimar o risco de pré-eclâmpsia de início precoce. Outra abordagem utilizada é a aplicação do princípio bayesiano para calcular o risco inicial com um modelo simples de regressão logística múltipla. Posteriormente, emprega-se a razão de verossimilhança, combinada com avaliações específicas, para refinar a estimativa do risco de pré-eclâmpsia.

Tais métodos geralmente requerem a aplicação de fórmulas distintas para avaliar o risco, incorporando uma variedade de indicadores preditivos (RANJBAR A, et al., 2024). Quanto ao Diabetes Mellitus Gestacional (DMG), uma condição que afeta significativamente a saúde da mãe e do feto, quatro estudos incluídos nesta revisão exploraram o uso de IA na sua predição (GUO Z, et al., 2020; ARTZI NS, et al., 2020; ZHANG H, et al., 2023; WATANABE M, et al., 2023).

Estes estudos refletem o esforço contínuo para melhorar a detecção precoce do DMG, uma condição que, se não gerenciada adequadamente, pode levar a complicações como macrosomia fetal, parto prematuro e aumento do risco de diabetes tipo 2 em mães após o parto.

Os modelos de IA aplicados nos estudos mostraram-se eficazes na análise de dados de prontuários eletrônicos e marcadores bioquímicos para identificar precocemente as gestantes em risco. Essa capacidade de detecção precoce é fundamental, pois permite intervenções mais rápidas e personalizadas, reduzindo potencialmente as complicações associadas ao DMG (WATANABE M, et al., 2023). Na identificação do DMG através de modelos de IA, diversos fatores são analisados para prever a condição com precisão. Estes modelos exploram um conjunto amplo de dados, que inclui não apenas as informações clínicas básicas, como

histórico médico e indicadores fisiológicos da mãe, mas também dados laboratoriais e biomarcadores. Parâmetros como níveis de glicose, perfil lipídico, IMC e histórico familiar de diabetes são integrados nos modelos de IA. Além disso, fatores como a idade da mãe, ganho de peso durante a gravidez, pressão arterial e até mesmo características genéticas podem ser considerados (SWEETING AN, et al., 2019).

Os algoritmos de IA são capazes de processar e analisar esses dados de maneira eficiente, identificando padrões e correlações que muitas vezes não são imediatamente evidentes.

Por meio do uso de técnicas avançadas, como aprendizado de máquina e análise de big data, esses modelos podem prever o risco de DMG com uma precisão significativamente maior do que os métodos convencionais. A IA tem a capacidade de considerar a complexa interação entre múltiplos fatores de risco, fornecendo uma avaliação de risco mais holística e personalizada para cada gestante (ZHANG H, et al., 2023; WATANABE M, et al., 2023).

Ainda à luz dos resultados desta revisão integrativa, o uso de prontuários eletrônicos emergiu como o método predominante para a coleta de dados nos estudos identificados.

As técnicas de IA demonstraram ser eficientes em extrair informações de conjuntos de dados derivados desses registros médicos eletrônicos (EMRs). A habilidade de detectar padrões dentro dos EMRs é fundamental para antecipar possíveis diagnósticos e auxiliar no planejamento do tratamento (HO CWL, et al., 2019). Além disso, a implementação de IA em EMRs pode ser enriquecida por outras grandes fontes de dados médicos, como informações genômicas e imagens diagnósticas. Essa integração de dados, por meio de algoritmos preditivos, tem potencial para aprimorar tanto o diagnóstico clínico quanto os protocolos de tratamento (HO CWL, et al., 2019).

Os EMRs tipicamente contêm informações variadas, incluindo dados demográficos, diagnósticos, marcadores bioquímicos, sinais vitais, anotações clínicas, prescrições e procedimentos. Estes são dados de fácil acesso e que minimizam os erros na manipulação de grandes volumes de informações. Estudos anteriores já haviam destacado a eficácia dos EMRs em ferramentas de previsão diagnóstica (NGUYEN P, et al., 2017; RAJKOMAR A, et al., 2018).

Deste modo, os achados desta revisão integrativa evidenciam a crescente influência e eficácia dos modelos de IA na obstetria, especialmente no que tange à predição e diagnóstico de complicações na gravidez. A análise dos estudos selecionados demonstra uma tendência clara na direção de um manejo obstétrico aprimorado, mediado pelo uso de IA, com destaque para a previsão de condições como pré-eclâmpsia e diabetes mellitus gestacional.

A integração de variáveis diversas provenientes de prontuários eletrônicos em modelos de IA representa um avanço importante, possibilitando a identificação precoce e mais precisa de riscos, o que é fundamental para uma intervenção clínica efetiva e oportuna.

Contudo, os resultados também apontam para desafios futuros, incluindo a necessidade de maior compreensão dos modelos de IA e a validação desses sistemas em ambientes clínicos variados. A aplicabilidade prática desses modelos em contextos clínicos distintos e a interpretação dos grandes conjuntos de dados de saúde requerem atenção adicional (MALACOVA E, et al., 2020).

CONSIDERAÇÕES FINAIS

Esta revisão integrativa realçou a importância e o potencial dos modelos de IA na predição e diagnóstico de complicações na gravidez, enfatizando avanços como a utilização de prontuários eletrônicos, análise de dados biomédicos e algoritmos preditivos. Estes modelos demonstraram uma melhoria significativa na precisão do diagnóstico de condições complexas como pré-eclâmpsia, diabetes mellitus gestacional, nascimento prematuro e invasão placentária, contribuindo para uma gestão mais efetiva da saúde materna e fetal. No entanto, apesar destes avanços promissores, a integração prática dessas tecnologias na prática obstétrica ainda enfrenta desafios notáveis, incluindo a necessidade de personalização para diferentes cenários clínicos, a garantia de precisão e confiabilidade dos modelos e as preocupações com a segurança

e privacidade dos dados dos pacientes. Ademais, esta pesquisa apresenta limitações, como a seleção e o escopo temporal dos estudos analisados e a não avaliação completa dos vieses potenciais presentes nos estudos. Portanto, são necessárias pesquisas futuras para superar esses desafios, validando e adaptando esses modelos de IA para uma aplicação mais ampla e eficaz na obstetria.

REFERÊNCIAS

1. AHMED Z, et al. Artificial Intelligence with Multi-Functional Machine Learning Platform Development for Better Healthcare and Precision Medicine. Database (Oxford). 2020; baaa010.
2. ARTZI NS, et al. Prediction of Gestational Diabetes Based on Nationwide Electronic Health Records. Nat. Med. 2020; 26(1): 71-76.
3. BRASIL. Ministério da Saúde (MS). Lei no 9.610, de 19 de fevereiro de 1998, que altera, atualiza e consolida a legislação sobre direitos autorais e dá outras providências. Diário Oficial da União. Brasília: Ministério da Saúde, 1998.
4. CARVALHO DV, et al. Machine Learning Interpretability: A Survey on Methods and Metrics. Electronics. 2019; 8: 832.
5. CECULA P. Artificial Intelligence: The Current State of Affairs for AI in Pregnancy and Labour. J. Gynecol. Obstet. Hum. Reprod. 2021; 50: 102048.
6. CERSONSKY TEK, et al. Identifying risk of stillbirth using machine learning. Am J Obstet Gynecol. 2023; 229(3): 327.e1-327.e16.
7. DHOMBRES F, et al. Contributions of Artificial Intelligence Reported in Obstetrics and Gynecology Journals: Systematic Review. J Med Internet Res. 2022; 24(4): e35465.
8. EDWARDS P, et al. Obesity in Pregnancy. Obstet. Gynaecol. Reprod. Med. 2020; 30: 315-320.
9. GAO C, et al. Learning to Identify Severe Maternal Morbidity from Electronic Health Records. Stud. Health Technol. Inform. 2019; 264: 143-147.
10. GUO Z, et al. Whole-Genome Promoter Profiling of Plasma DNA Exhibits Diagnostic Value for Placenta-Origin Pregnancy Complications. Adv. Sci. 2020; 7(7): 1901819.
11. HO CWL, et al. Governance of Automated Image Analysis and Artificial Intelligence Analytics in Healthcare. Clin. Radiol. 2019; 74: 329-337.
12. IFTIKHAR PM, et al. Artificial Intelligence: A New Paradigm in Obstetrics and Gynecology Research and Clinical Practice. Cureus, 2020; 12: e7124.
13. JHEE JH, et al. Prediction Model Development of Late-Onset Preeclampsia Using Machine Learning-Based Methods. PLoS ONE. 2019; 14(8): e0221202.
14. KHATIBI T, et al. Analysis of Big Data for Prediction of Provider-Initiated Preterm Birth and Spontaneous Premature Deliveries and Ranking the Predictive Features. Arch. Gynecol. Obstet. 2019; 300(6): 1565-1582.
15. LI YX, et al. Novelelectronic health records applied for prediction of pre-eclampsia: Machine-learning algorithms. Pregnancy Hypertens. 2021; 26:102-109.
16. LIU M, et al. Development of a prediction model on preeclampsia using machine learning-based method: a retrospective cohort study in China. Front Physiol. 2022; 13: 896969.
17. MALACOVA E, et al. Stillbirth Risk Prediction Using Machine Learning for a Large Cohort of Births from Western Australia, 1980-2015. Sci. Rep. 2020; 10(1): 5354.
18. MARIONA FG. Perspectives in Obesity and Pregnancy. Womens Health (Lond). 2016; 12: 523-532.
19. MCHUGH ML. Interrater reliability: the kappa statistic. Biochemia Medica, 2012; 22(3): 276-282.
20. MENDES KDS, et al. Use of the bibliographic reference manager in the selection of primary studies in integrative reviews. Texto Contexto Enferm. 2019; 28: e20170204.
21. PAPADA SM. Machine learning in medicine: It has arrived, let's embrace it. J Card Surg. 2021; 36(11): 4121-4124.
22. NGUYEN P, et al. $\{Deepr\}$: A Convolutional Net for Medical Records. IEEE J. Biomed. Health Inform. 2017; 21, 22–30.
23. PEREIRA AS, et al. Metodologia da pesquisa científica. (1ª ed.): UFSM, NTE, 2018.
24. POON LC, et al. Early prediction of preeclampsia. Obstet Gynecol Int. 2014; 2014: 297397.
25. RAHMAN A, et al. Impact of Artificial Intelligence (AI) Technology in Healthcare Sector: A Critical Evaluation of Both Sides of the Coin. Clin Pathol. 2024; 17:2632010X241226887.
26. RAJKOMAR A, et al. Scalable and Accurate Deep Learning with Electronic Health Records. Npj Digital Med. 2018; 1, 18.

27. RANJBAR A, et al. Machine learning models for predicting preeclampsia: a systematic review. *BMC Pregnancy Childbirth*. 2024; 24: 6.
28. RITTENHOUSE KJ, et al. Improving Preterm Newborn Identification in Low-Resource Settings with Machine Learning. *PLoS One*. 2019; 14(2): e0198919.
29. SHARMA DD, et al. The Management of Preeclampsia: A Comprehensive Review of Current Practices and Future Directions. *Cureus*. 2024; 16(1): e51512.
30. SIRCAR M, et al. Pathogenesis of preeclampsia. *Curr Opin Nephrol Hypertens*. 2015; 24(2): 131-8.
31. STILLWELL S, et al. Evidence– based practice: step by step. *Am J Nurs*, 2010; 110(5): 41-47.
32. SUFRIYANA H, et al. Comparison of Multivariable Logistic Regression and Other Machine Learning Algorithms for Prognostic Prediction Studies in Pregnancy Care: Systematic Review and Meta-Analysis. *JMIR Med Inform*. 2020; 8(11): e16503.
33. SUN H, et al. Identification of Suspicious Invasive Placentation Based on Clinical MRI Data Using Textural Features and Automated Machine Learning. *Eur. Radiol*. 2019; 29(11): 6152-6162.
34. SWEETING AN, et al. A Novel Early Pregnancy Risk Prediction Model for Gestational Diabetes Mellitus. *Fetal Diagn Ther*. 2019; 45(2): 76-84.
35. WATANABE M, et al. Prediction of gestational diabetes mellitus using machine learning from birth cohort data of the Japan Environment and Children's Study. *Sci Rep*. 2023; 13(1): 17419.
36. WHITTEMORE R, et al. The integrative review: updated methodology. *J Adv Nurs*. 2005; 52(5):546-53.
37. WORLD HEALTH ORGANIZATION (WHO). WHO recommendations on intrapartum care for a positive childbirth experience. World Health Organization; 2018.
38. WORLD HEALTH ORGANIZATION (WHO). Trends in Maternal Mortality: 2000 to 2017: Estimates by WHO, UNICEF, UNFPA, World Bank Group and the United Nations Population Division. 2019. Geneva: World Health Organization. WHO, UNICEF, UNFPA, World Bank Group and the United Nations Population Division.
39. ZHANG H, et al. Integration of clinical demographics and routine laboratory analysis parameters for early prediction of gestational diabetes mellitus in the Chinese population. *Front Endocrinol (Lausanne)*. 2023; 14:1216832.