

**APLICAÇÃO DO APRENDIZADO DE MÁQUINA NO DIAGNÓSTICO DA GRAVIDEZ ECTÓPICA: UMA REVISÃO BIBLIOGRÁFICA****APPLICATION OF MACHINE LEARNING IN THE DIAGNOSIS OF ECTOPIC PREGNANCY: A LITERATURE REVIEW****APLICACIÓN DEL APRENDIZAJE AUTOMÁTICO EN EL DIAGNÓSTICO DEL EMBARAZO ECTÓPICO: UNA REVISIÓN BIBLIOGRÁFICA**Pedro Clarindo Silva Neto¹, Rafael Kunst², Ricardo Francalacci Savaris³

e666533

<https://doi.org/10.47820/recima21.v6i6.6533>

PUBLICADO: 6/2025

RESUMO

Este artigo realizou uma revisão bibliográfica sobre o uso de aprendizado de máquina (ML) no diagnóstico de gravidez ectópica (EP). Foram analisados estudos publicados entre 2020 e 2024, utilizando critérios rigorosos de inclusão e exclusão. Os resultados mostram que técnicas avançadas, como redes neurais convolucionais, algoritmos bayesianos e máquinas de vetores de suporte, apresentam alta precisão diagnóstica, especialmente ao integrar múltiplas fontes de dados, como informações clínicas, laboratoriais e ultrassonográficas. Esses modelos demonstraram potencial para reduzir erros clínicos e melhorar a eficiência diagnóstica, superando limitações dos métodos tradicionais. No entanto, desafios como a falta de validação clínica robusta, a escassez de dados representativos e a complexidade dos modelos, que muitas vezes operam como "caixas pretas", ainda impedem sua implementação prática. Esta revisão contribui para um entendimento mais claro do estado da arte, destacando as abordagens mais eficazes, os principais desafios e as oportunidades para futuras pesquisas. A adoção responsável dessas tecnologias tem potencial para transformar o diagnóstico da EP, melhorando a segurança e os resultados clínicos das pacientes.

PALAVRAS-CHAVE: Gravidez ectópica. Aprendizado de máquina. Inteligência artificial. Diagnóstico clínico. Ultrassonografia.

ABSTRACT

This paper presents literature review on the use of machine learning (ML) in the diagnosis of ectopic pregnancy (EP). Studies published between 2020 and 2024 were analyzed using rigorous inclusion and exclusion criteria. Results show that advanced techniques, such as convolutional neural networks, Bayesian algorithms, and support vector machines, achieve high diagnostic accuracy, especially when integrating multiple data sources, including clinical, laboratory, and ultrasound information. These models demonstrated potential to reduce clinical errors and improve diagnostic efficiency, overcoming limitations of traditional methods. However, challenges such as the lack of robust clinical validation, scarcity of representative data, and the complexity of models, often seen as "black boxes," still hinder their practical implementation. This review contributes to a clearer understanding of the state of the art, highlighting the most effective approaches, main challenges, and opportunities for future research. The responsible adoption of these technologies has the potential to transform EP diagnosis, improving patient safety and clinical outcomes.

KEYWORDS: Ectopic pregnancy. Machine learning. Artificial intelligence. Clinical diagnosis. Ultrasonography.

¹ Universidade do Vale do Rio dos Sinos - UNISINOS / IFMT.

² Universidade do Vale do Rio dos Sinos - UNISINOS.

³ Universidade Federal do Rio Grande do Sul - UFRGS.



RESUMEN

Este artículo presenta una revisión bibliográfica sobre el uso del aprendizaje automático (ML) en el diagnóstico del embarazo ectópico (EP). Se analizaron estudios publicados entre 2020 y 2024, utilizando criterios rigurosos de inclusión y exclusión. Los resultados muestran que técnicas avanzadas, como redes neuronales convolucionales, algoritmos bayesianos y máquinas de vectores de soporte, presentan alta precisión diagnóstica, especialmente al integrar múltiples fuentes de datos, como información clínica, de laboratorio y ultrasonográfica. Estos modelos demostraron potencial para reducir errores clínicos y mejorar la eficiencia diagnóstica, superando limitaciones de los métodos tradicionales. Sin embargo, desafíos como la falta de validación clínica robusta, la escasez de datos representativos y la complejidad de los modelos, que a menudo operan como "cajas negras", aún impiden su implementación práctica. Esta revisión contribuye a una comprensión más clara del estado del arte, destacando los enfoques más efectivos, los principales desafíos y las oportunidades para futuras investigaciones. La adopción responsable de estas tecnologías tiene el potencial de transformar el diagnóstico de EP, mejorando la seguridad y los resultados clínicos de las pacientes.

PALABRAS CLAVE: Embarazo ectópico. Aprendizaje automático. Inteligencia artificial. Diagnóstico clínico. Ultrasonografía.

INTRODUÇÃO

A gestação ectópica (EP) é uma condição clínica de diagnóstico complexo, particularmente nos estágios iniciais, quando os sintomas podem ser vagos e facilmente confundidos com outras complicações da gravidez. A EP, que se caracteriza pela colocação do óvulo fertilizado fora do útero, normalmente nas trompas de Falópio, é uma emergência médica que, se não for detectada e tratada a tempo, pode resultar em complicações sérias, como sangramentos internos, rompimento de tubulações e, em situações extremas, até mesmo na morte da mulher grávida. A prevalência de gravidez ectópica tem crescido nas últimas décadas, contribuindo para uma parte considerável da morbimortalidade materna globalmente (Mullany *et al.*, 2023; Savaris *et al.*, 2022).

Diante desse cenário, a busca por métodos diagnósticos mais precisos e rápidos é essencial para melhorar os desfechos clínicos e garantir a segurança das pacientes. Os métodos convencionais de diagnóstico, como a ultrasonografia transvaginal (TVUS) e a dosagem sérica de gonadotrofina coriônica humana (hCG), embora sejam amplamente utilizados, apresentam limitações significativas. A interpretação dos resultados desses exames depende da experiência do profissional, e em muitos casos, especialmente nas fases iniciais da gestação, os achados podem ser inconclusivos, levando a diagnósticos tardios e aumentando o risco de complicações (Fistouris *et al.*, 2022; MA *et al.*, 2022).

Nesse contexto, o aprendizado de máquina (ML - *Machine Learning*) emerge como uma abordagem promissora, capaz de superar as limitações dos métodos convencionais. A capacidade do ML de integrar e analisar grandes volumes de dados clínicos, laboratoriais e de imagem em tempo real oferece uma oportunidade única para aprimorar a precisão diagnóstica da



EP. Técnicas avançadas, como aprendizado profundo (Deep Learning), modelos bayesianos e algoritmos supervisionados, têm sido exploradas para identificar padrões complexos e fornecer diagnósticos mais confiáveis (Shaban *et al.*, 2024; Rueangket; Rittiluechai; Prayote, 2022).

Pesquisas recentes ressaltam a capacidade dessas metodologias para diminuir falhas clínicas e aprimorar a eficácia diagnóstica. Por exemplo, modelos que utilizam redes neurais convolucionais (CNNs) têm mostrado elevada acurácia na avaliação de imagens ultrassonográficas, ao passo que algoritmos bayesianos têm se mostrado eficientes na combinação de diversos marcadores clínicos e laboratoriais para antecipar o risco de epilepsia (Savaris *et al.*, 2022; Rueangket; Rittiluechai; Prayote, 2022). Contudo, a implementação prática do *Machine Learning* na medicina se depara com obstáculos consideráveis, tais como a exigência de uma validação clínica sólida, a falta de dados representativos e a complexidade dos modelos, frequentemente percebidos como "caixas pretas" devido à dificuldade em entender suas decisões internas. Esses elementos têm o potencial de restringir a aceitação e a aplicação dessas tecnologias em contextos clínicos reais. (Heinrichs; Eickhoff, 2020; Poon; Sung, 2021).

Além disso, a heterogeneidade dos dados médicos, que incluem informações clínicas, laboratoriais e de imagem, representa um desafio adicional para a aplicação do ML. A integração dessas diferentes fontes de dados em um único modelo preditivo requer técnicas avançadas de pré-processamento e análise, bem como a colaboração interdisciplinar entre profissionais de saúde e cientistas de dados (Ellis; Sander; Limon, 2022; Couckuyt *et al.*, 2022). A falta de padronização nos dados médicos, aliada à necessidade de garantir a privacidade e a segurança das informações dos pacientes, também são questões críticas que precisam ser abordadas para que o ML possa ser amplamente adotado na prática clínica (Bowman, 2022).

Diante dessas considerações, este artigo busca responder a duas questões principais: (i) quais são os modelos e arquiteturas de aprendizado de máquina atualmente aplicados ao diagnóstico da gravidez ectópica? e (ii) quais são os principais desafios e limitações enfrentados na aplicação prática desses modelos em contextos clínicos reais? Para responder a essas perguntas, foi realizada uma revisão bibliográfica da literatura científica recente, abrangendo publicações entre 2020 e 2024 nas principais bases de dados acadêmicas. A metodologia adotada permitiu identificar os métodos mais frequentemente utilizados no diagnóstico da EP, analisar suas vantagens e limitações, e destacar lacunas e perspectivas futuras de pesquisa (Kitchenham, 2004).

Este estudo realizou uma revisão bibliográfica com o objetivo de analisar os métodos de aprendizado de máquina (ML) aplicados ao diagnóstico da gravidez ectópica. A revisão foi estruturada, seguindo critérios rigorosos para garantir a relevância e qualidade dos artigos selecionados, utilizando uma abordagem metodológica baseada nas etapas propostas por Kitchenham (2004). A revisão é amplamente reconhecida como uma ferramenta eficaz para



mapear o estado da arte em uma área de pesquisa, identificando lacunas e direcionando futuros estudos (Dalzochio, 2024).

Ao abordar aspectos como populações-alvo, intervenções diagnósticas e resultados esperados, foi possível estabelecer uma base consistente para a contextualização e a análise crítica das contribuições identificadas na literatura. Os principais objetivos desta revisão foram: (i) identificar os modelos e arquiteturas de aprendizado de máquina empregados no diagnóstico da gravidez ectópica, destacando suas características técnicas; (ii) analisar os principais desafios associados à aplicação prática desses modelos, incluindo o tratamento de dados ausentes e a integração de múltiplas fontes de dados; e (iii) avaliar criticamente a eficácia dos métodos descritos na literatura, destacando possíveis oportunidades para futuras pesquisas.

Este artigo visa contribuir para um entendimento mais claro sobre o estado da arte na utilização do aprendizado de máquina para o diagnóstico da gravidez ectópica, destacando as abordagens mais eficazes, os principais desafios enfrentados e as oportunidades para futuras pesquisas e aplicações práticas na área clínica. Ao explorar as potencialidades e os limites do ML no contexto da EP, espera-se fornecer *insights* valiosos para pesquisadores e profissionais de saúde, promovendo a adoção responsável e eficaz dessas tecnologias em benefício das pacientes.

1. MÉTODO

Com base nos desafios científicos e nas contribuições identificadas durante a revisão, foram definidas a questão principal (MQ) e as subquestões (SQ) que norteiam esta pesquisa. A formulação dessas questões busca estruturar a investigação de maneira abrangente, permitindo uma análise detalhada dos aspectos técnicos, metodológicos e práticos relacionados ao uso de aprendizado de máquina no diagnóstico de gravidez ectópica.

A questão principal (MQ) foi formulada com o objetivo de identificar e analisar os modelos e arquiteturas de aprendizado de máquina utilizados no diagnóstico de gravidez ectópica, fornecendo um panorama abrangente do estado da arte na área. Essa questão é central para entender como as soluções existentes abordam os desafios diagnósticos e quais lacunas permanecem sem solução.

Para complementar e detalhar a MQ, foram elaboradas subquestões específicas que exploram dimensões fundamentais do problema. A SQ1 concentra-se nas abordagens mais comumente utilizadas para classificar casos de gravidez ectópica, analisando desde os algoritmos empregados até os critérios para seleção de variáveis. A SQ2 investiga como os modelos são avaliados, com foco em métricas como precisão, sensibilidade, especificidade e robustez no contexto clínico. Por fim, a SQ3 examina os desafios e limitações enfrentados na aplicação de



aprendizado de máquina, incluindo aspectos técnicos, como tratamento de dados ausentes, e contextuais, como a adoção em ambientes clínicos reais.

Para as buscas, realizadas em dezembro de 2024 e restritas a publicações a partir de 2020, foi fundamental criar uma *string* de busca e selecionar as bases de dados adequadas. Inicialmente, a pesquisa foi realizada no Google Acadêmico¹, devido à sua capacidade de busca livre nos títulos e textos das publicações. Em seguida, a revisão foi conduzida nas bases acadêmicas específicas Association for Computing Machinery (ACM) Digital Library², Institute of Electrical and Electronics Engineers (IEEE) Xplore³, ScienceDirect⁴, Scopus⁵ e Public Medline (PubMed)⁶, garantindo abrangência e relevância acadêmica. O objetivo foi obter um maior volume de resultados para identificar estudos relevantes e possíveis desafios no diagnóstico de gravidez ectópica utilizando aprendizado de máquina.

A *string* utilizada foi formada pelos descritores da saúde: *ectopic pregnancy*, *machine learning*, *ultrasound* e *model*. Essa *string* foi projetada para abranger uma ampla gama de publicações relevantes, garantindo que estudos que abordassem o uso de ML no diagnóstico de gravidez ectópica fossem capturados de forma eficiente.

A escolha dessas bases foi estratégica, pois elas cobrem uma ampla variedade de publicações científicas, desde artigos de conferências até periódicos de alto impacto. Para garantir a atualidade dos estudos, foi aplicado um filtro para publicações a partir de 2020, excluindo patentes e citações. A busca inicial no Google Acadêmico resultou em 857 ocorrências, que foram exportadas para o *software* Mendeley para triagem detalhada.

Para selecionar os estudos mais pertinentes, foram adotados cinco critérios específicos de exclusão, conforme descrito abaixo:

- Critério 1: Artigos publicados antes de 2020.
- Critério 2: Relatórios técnicos, dissertações e teses.
- Critério 3: Documentos repetidos ou com menos de quatro páginas.
- Critério 4: Publicações que não mencionavam explicitamente "gravidez ectópica", "detecção precoce de gravidez" ou "complicações na gravidez" no título, resumo ou palavras-chave.
- Critério 5: Artigos que não abordavam diretamente o uso de ML ou inteligência artificial com dados clínicos específicos, como ultrassom, marcadores clínicos ou hCG.

¹ <https://scholar.google.com/>

² <https://dl.acm.org/>

³ <https://ieeexplore.ieee.org/>

⁴ <https://www.sciencedirect.com/>

⁵ <https://www.scopus.com/>

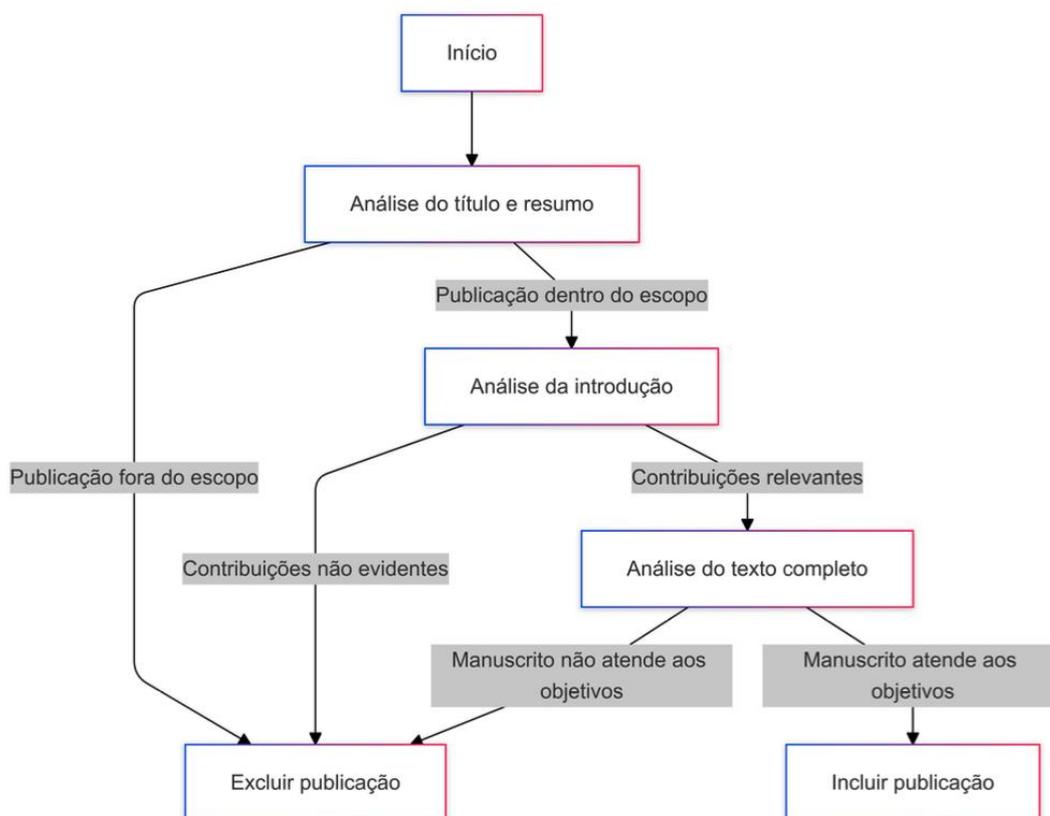
⁶ <https://pubmed.ncbi.nlm.nih.gov/>

Após a aplicação desses critérios, foram selecionados 45 artigos para leitura completa. Destes, apenas aqueles que contribuíram diretamente para os objetivos propostos foram mantidos, totalizando um número menor, rigorosamente alinhado com o escopo desta pesquisa.

O processo metodológico de seleção dos artigos seguiu as etapas ilustradas na Figura 1. Inicialmente, foi realizada uma análise prévia dos títulos e resumos para verificar a aderência ao escopo do estudo. Essa etapa foi essencial para filtrar estudos que não contribuíssem para os objetivos propostos, garantindo maior eficiência no processo de triagem.

Posteriormente, os textos com potencial relevância foram submetidos à leitura da introdução, e aqueles que apresentaram contribuições claras e alinhadas aos objetivos desta revisão foram analisados integralmente. Em casos em que o título, o resumo e a introdução não foram suficientes para determinar a relevância do manuscrito, procedeu-se a uma análise completa do texto. Esse processo garantiu maior precisão na inclusão dos estudos, conforme representado na Figura 1.

Figura 1. Fluxograma do processo metodológico para seleção dos artigos



Fonte: elaborado pelo autor (2025).



Os resultados dessa revisão bibliográfica forneceram uma base sólida para discussão e proposição de futuras pesquisas sobre a aplicação de aprendizado de máquina no diagnóstico da gravidez ectópica. A metodologia adotada permitiu identificar os métodos mais frequentemente utilizados no diagnóstico da EP, analisar suas vantagens e limitações, e destacar lacunas e perspectivas futuras de pesquisa (Kitchenham, 2004).

2. RESULTADOS

Os resultados desta revisão identificaram diferentes abordagens utilizadas na aplicação do aprendizado de máquina (ML) para o diagnóstico de gravidez ectópica (EP). Os métodos mais frequentemente relatados na literatura incluem a ultrassonografia transvaginal (TVUS) associada a biomarcadores séricos, modelos estatísticos como regressão logística, redes neurais (NNs), árvores de decisão (DT) e máquinas de vetores de suporte (SVMs). A ultrassonografia mostrou-se uma ferramenta preferencial devido à sua capacidade de identificar diretamente o local da implantação gestacional, destacada por estudos como os de Mullany *et al.*, (2023) e Savaris *et al.*, (2022). Além disso, a combinação de dados ultrassonográficos com biomarcadores séricos, como a gonadotrofina coriônica humana (hCG), tem sido amplamente utilizada para aumentar a precisão diagnóstica, especialmente em casos em que a localização da gravidez é incerta.

Modelos baseados em biomarcadores séricos, especialmente a medição seriada da hCG, apresentaram destaque pela sua eficácia em distinguir entre gestações normais e ectópicas. Além disso, novos biomarcadores, como ativina-AB e proteína plasmática A associada à gravidez (PAPP-A), vêm sendo estudados para potencializar a precisão diagnóstica (Ma *et al.*, 2022). Esses biomarcadores, quando combinados com técnicas de ML, permitem uma análise mais refinada e personalizada, adaptando-se às características individuais de cada paciente. Essa abordagem multimodal tem se mostrado particularmente útil em casos complexos, onde os métodos tradicionais falham em fornecer diagnósticos conclusivos.

Técnicas avançadas, incluindo aprendizado profundo, redes neurais convolucionais (CNNs), árvores de decisão e máquinas de vetores de suporte (SVMs), foram analisadas, demonstrando desempenhos promissores, principalmente em validação externa. Particularmente, redes neurais destacaram-se por sua capacidade de integração multimodal de dados clínicos, laboratoriais e de imagem, oferecendo um alto nível de precisão diagnóstica (Rueangkit; Rittiluechai; Prayote, 2022). A capacidade desses modelos de processar grandes volumes de dados e identificar padrões complexos tem sido fundamental para melhorar a detecção precoce da EP, especialmente em estágios iniciais da gestação.

Modelos Bayesianos também foram destacados devido à capacidade de integração de dados diversos, como níveis de hCG e achados ultrassonográficos, permitindo um diagnóstico preciso com sensibilidade e especificidade elevadas, conforme reportado por Savaris *et al.*,



(2022). Além disso, modelos preditivos específicos, como o M6NP e o M4, mostraram-se eficazes na estimativa precoce de risco para EP em mulheres com gravidez de localização desconhecida (Fistouris; Bergh; Strandell, 2022). Esses modelos têm sido particularmente úteis em cenários de emergência, onde a rapidez e a precisão do diagnóstico são críticas para a segurança da paciente.

Entre os desafios relatados, destacam-se a necessidade de validação em cenários clínicos reais, problemas de sobreajuste e generalização limitada dos modelos devido à falta de dados abrangentes e representativos. Ademais, a interpretabilidade reduzida dos modelos complexos de ML representa uma barreira significativa para sua aceitação clínica, conforme discutido por Heinrichs e Eickhoff (2020) e Poon e Sung (2021). A falta de transparência nos mecanismos internos desses modelos pode gerar desconfiança entre os profissionais de saúde, limitando sua adoção em ambientes clínicos.

Esses resultados indicam que, apesar dos desafios, o aprendizado de máquina possui potencial significativo para aprimorar a precisão diagnóstica da gravidez ectópica, desde que abordagens robustas de validação clínica e calibração sejam realizadas de forma rigorosa, atendendo às necessidades práticas e éticas em ambientes reais. A integração de múltiplas fontes de dados e o desenvolvimento de modelos mais interpretáveis são passos essenciais para superar as barreiras atuais e garantir a implementação eficaz dessas tecnologias na prática clínica.

Os principais desafios e limitações encontrados na aplicação do aprendizado de máquina (ML) para diagnóstico da gravidez ectópica foram categorizados em técnicos, clínicos e éticos-legais, conforme sintetizado na Tabela 1. Esses desafios representam barreiras relevantes que precisam ser superadas para garantir a efetiva implementação clínica dessas tecnologias.

Tabela 1. Desafios e Limitações na Aplicação de ML para Diagnósticos de Gravidez Ectópica

Categoria	Desafios e Limitações
Desafios Técnicos	<ul style="list-style-type: none"> - Responsabilidade: Diretrizes pouco claras sobre quem responde por erros do modelo (HEINRICHES; EICKHOFF, 2020); (BOWMAN, 2022)) - Confiança do paciente: Hesitação de médicos e pacientes devido a incertezas na precisão e confiabilidade do ML (POON; SUNG,2021); (SHAZLY <i>et al.</i>, 2022)) - Qualidade e disponibilidade de dados: Dados



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

APLICAÇÃO DO APRENDIZADO DE MÁQUINA NO DIAGNÓSTICO DA GRAVIDEZ ECTÓPICA: UMA REVISÃO BIBLIOGRÁFICA
Pedro Clarindo Silva Neto, Rafael Kunst, Ricardo Francalacci Savaris

	<p>limitados e pouco diversificados dificultam a generalização dos modelos (MEN-NICKENT <i>et al.</i>, 2023); (BOWMAN, 2022))</p> <p>- Interpretabilidade: Modelos de "caixa preta" complicam a aceitação clínica devido à falta de transparência (HEINRICHS; EICKHOFF, 2020); (POON; SUNG, 2021))</p> <p>- Generalização e sobreajuste: Modelos podem falhar em novos dados, impactando a precisão diagnóstica (RUEANGKET; RITTILUECHAI; PRAYOTE, 2022); (COUCKUYT <i>et al.</i>, 2022))</p>
Desafios Clínicos	<p>- Integração no fluxo de trabalho: Adoção complexa nos sistemas clínicos existentes sem interrupções ((COUCKUYT <i>et al.</i>, 2022); (SHAZLY <i>et al.</i>, 2022))</p> <p>- Validação clínica: Necessidade de validação em ambientes reais para garantir confiabilidade e impacto positivo ((MENNICKENT <i>et al.</i>, 2023); (ELLIS; SANDER; LIMON, 2022))</p>
Desafios Éticos e Legais	<p>- Responsabilidade: Diretrizes pouco claras sobre quem responde por erros do modelo (HEINRICHS; EICKHOFF, 2020); (BOWMAN, 2022))</p> <p>- Confiança do paciente: Hesitação de médicos e pacientes devido a incertezas na precisão e confiabilidade do ML (POON; SUNG, 2021); (SHAZLY <i>et al.</i>, 2022))</p>

Fonte: elaborado pelo autor (2025).

A implementação efetiva do aprendizado de máquina no diagnóstico da gravidez ectópica, além dos desafios mencionados, exige uma estratégia colaborativa e interdisciplinar. É fundamental a colaboração entre médicos, cientistas de dados e especialistas em ética para a criação de modelos clinicamente pertinentes e tecnicamente sólidos. A formação dos profissionais de saúde e a adequação dos sistemas clínicos, que inclui a normalização de dados e a elaboração de protocolos transparentes, são etapas cruciais para assegurar a aceitação e



implementação dessas tecnologias. Tais ações podem simplificar a mudança para uma medicina mais exata e fundamentada em evidências, favorecendo as pacientes com gravidez ectópica.

3. DISCUSSÃO

A revisão realizada evidenciou que o uso do aprendizado de máquina (ML) oferece uma significativa contribuição para o diagnóstico da gravidez ectópica (EP), principalmente ao permitir a integração eficiente de múltiplas fontes de dados, como clínicos, laboratoriais e de imagem. Estudos como os realizados por Shaban *et al.*, (2024) e Rueangket, Rittiluechai e Prayote (2022) destacam que modelos baseados em aprendizado profundo, especialmente as redes neurais convolucionais (CNNs), podem superar limitações tradicionais associadas à ultrassonografia e aos biomarcadores séricos, apresentando alta capacidade discriminativa e desempenho promissor em testes externos.

Entretanto, apesar dos avanços identificados, os desafios permanecem expressivos. A falta de dados representativos e completos é uma limitação crítica, pois influencia diretamente na generalização dos modelos. Modelos treinados em conjuntos de dados restritos podem apresentar resultados tendenciosos ou com desempenho reduzido em contextos diferentes dos originais (Mennickent *et al.*, 2023; Bowman, 2022).

Outro ponto destacado como fundamental é a interpretabilidade dos modelos de aprendizado profundo, frequentemente vistos como "caixas pretas" devido à complexidade interna de seus algoritmos. A ausência de transparência nos mecanismos internos desses modelos cria obstáculos na aceitação clínica, pois os profissionais necessitam compreender claramente a lógica das decisões algorítmicas para sua aplicação prática (Heinrichs; Eickhoff, 2020).

Adicionalmente, a validação rigorosa em contextos clínicos reais é essencial para garantir robustez e aplicabilidade dos modelos propostos. A revisão indicou que a ausência de validação adequada pode gerar dúvidas quanto à efetividade real dos modelos, levando a resistências por parte de profissionais da saúde. Estudos como os de Mennickent *et al.*, (2023) e Ellis, Sander e Limon (2022) reforçam a necessidade de estudos aprofundados e testes interhospitalares para avaliar a robustez dos modelos antes da implementação clínica.

Por fim, as questões éticas e legais destacam-se como fundamentais. O uso clínico de modelos baseados em aprendizado de máquina demanda clareza em termos de responsabilidade pelas decisões tomadas, especialmente em casos de erros diagnósticos. Além disso, a confiança dos profissionais e pacientes na tecnologia é um desafio constante, exigindo estratégias claras para promover maior transparência, responsabilidade e aceitação das ferramentas diagnósticas baseadas em inteligência artificial (Poon; Sung, 2021; Shazly *et al.*, 2022).

O uso de algoritmos de aprendizado de máquina na medicina tem se mostrado uma ferramenta poderosa para melhorar diagnósticos, prognósticos e a descoberta de novos



tratamentos. Conforme destacado por Garzon e Barbosa (2023), a aplicação desses algoritmos permite a análise de grandes volumes de dados médicos, como imagens de exames e registros eletrônicos de saúde, identificando padrões sutis que podem levar a diagnósticos mais precisos e personalizados. Além disso, os autores ressaltam que, apesar dos avanços, desafios como a privacidade dos dados, a interpretabilidade dos modelos e a necessidade de validação clínica robusta ainda precisam ser superados para garantir a implementação ética e eficaz dessas tecnologias na prática médica.

Esses aspectos ressaltam a importância de um desenvolvimento colaborativo e interdisciplinar entre médicos e cientistas de dados, garantindo modelos robustos, confiáveis e clinicamente relevantes, capazes de contribuir positivamente para a prática médica e segurança dos pacientes.

4. CONSIDERAÇÕES

Esta revisão bibliográfica identificou e examinou várias técnicas de aprendizado de máquina empregadas no diagnóstico clínico da gravidez ectópica, enfatizando métodos como o aprendizado profundo, redes neurais convolucionais e algoritmos de Bayes. Essas metodologias evidenciaram elevada acurácia diagnóstica e habilidade para integrar dados complexos e diversificados, tais como dados clínicos, laboratoriais e de imagem. Os achados sugerem que esses procedimentos têm um enorme potencial para aprimorar consideravelmente a exatidão e a rapidez no diagnóstico clínico, particularmente em situações em que os métodos tradicionais apresentam restrições. A habilidade de integrar diversas fontes de dados em um único modelo preditivo possibilita uma estratégia mais completa e personalizada, o que pode resultar em diagnósticos mais antecipados e exatos.

No entanto, é fundamental considerar os desafios técnicos e práticos associados ao uso dessas tecnologias. A qualidade e diversidade dos dados utilizados nos modelos representam um dos principais obstáculos. Conjuntos de dados limitados ou pouco representativos podem resultar em modelos que funcionam bem em ambientes controlados, mas falham em contextos clínicos reais, onde a variabilidade dos pacientes e das condições médicas é significativamente maior. Além disso, a falta de padronização nos dados médicos, que podem variar entre diferentes instituições e regiões, dificulta a criação de modelos que sejam amplamente aplicáveis e confiáveis.

Outro desafio crítico é a complexidade dos modelos de aprendizado de máquina, especialmente aqueles baseados em técnicas de aprendizado profundo. Esses modelos, embora altamente precisos, muitas vezes operam como "caixas pretas", onde a lógica interna das decisões não é facilmente compreensível para os profissionais de saúde. Essa falta de transparência pode gerar desconfiança entre médicos e pacientes, limitando a adoção clínica



dessas tecnologias. Para superar essa barreira, é essencial que futuras pesquisas desenvolvam métodos que tornem os modelos mais interpretáveis, permitindo que os profissionais de saúde entendam e validem as decisões tomadas pelos algoritmos.

Outra questão vital que precisa ser priorizada é a validação clínica sólida. Numerosos dos modelos examinados nesta revisão foram avaliados em contextos controlados ou com conjuntos de dados específicos, o que pode não espelhar a complexidade e a variedade presentes na prática clínica concreta. Pesquisas multicêntricas e validações externas são imprescindíveis para assegurar a confiabilidade e aplicabilidade dos modelos de aprendizado de máquina em variados cenários clínicos. Ademais, a cooperação interdisciplinar entre médicos, cientistas de dados e especialistas em ética é crucial para assegurar que os modelos sejam criados e aplicados de forma responsável, satisfazendo as demandas clínicas e salvaguardando os direitos dos pacientes.

As questões éticas também desempenham um papel central na implementação do aprendizado de máquina na medicina. A privacidade e a segurança dos dados dos pacientes são preocupações críticas, especialmente em um contexto em que grandes volumes de informações sensíveis são coletados e analisados. É essencial que os modelos de aprendizado de máquina sejam desenvolvidos em conformidade com as regulamentações de proteção de dados, garantindo que os direitos dos pacientes sejam preservados. Além disso, a responsabilidade pelas decisões tomadas por algoritmos de aprendizado de máquina ainda é um tema em discussão, exigindo diretrizes claras sobre como lidar com erros diagnósticos ou prognósticos gerados por esses sistemas.

Assim, sugere-se que estudos futuros foquem na execução de validações sólidas em variados cenários clínicos, incentivem a cooperação interdisciplinar e deem prioridade à transparência e ética na implementação de modelos fundamentados em aprendizado de máquina. A implementação consciente e meticulosa dessas tecnologias pode alterar de forma positiva o diagnóstico clínico da gravidez ectópica, auxiliando em resultados mais eficazes para a saúde e segurança das pacientes. Ademais, é crucial que os profissionais da saúde sejam treinados para compreender e empregar essas novas ferramentas, assegurando que as vantagens do aprendizado de máquina sejam totalmente aplicadas na prática clínica.

Em última análise, a incorporação do aprendizado de máquina no diagnóstico da gravidez ectópica oferece uma chance significativa de progresso na medicina personalizada, na qual os tratamentos e intervenções podem ser ajustados de acordo com as particularidades de cada paciente. Contudo, para atingir esse potencial, é imprescindível um empenho constante para vencer os obstáculos técnicos, éticos e práticos ligados a essas tecnologias. A comunidade médica e científica precisa colaborar para assegurar que a implementação do aprendizado de



máquina seja feita de forma ética, segura e eficiente, trazendo vantagens para os profissionais da saúde e os pacientes.

REFERÊNCIAS

BOWMAN, C. E. There is nothing medically magical about machine learning. **Journal of the Royal Society of Medicine**, v. 115, n. 9, p. 332, 2022.

COUCKUYT, A.; SEURINCK, R.; EMMANEEL, A. et al. Challenges in translational machine learning. **Human Genetics**, v. 141, p. 1451-1466, 2022.

DALZOCHIO, J. **MILPDM**: an architecture for predictive maintenance of assets in the military domain. 2024. Tese (Doutorado em Ciência da Computação) -- Universidade do Vale do Rio dos Sinos (UNISINOS), 2024.

ELLIS, R. J.; SANDER, R. M.; LIMON, A. Twelve key challenges in medical machine learning and solutions. **Intelligence-Based Medicine**, v. 6, p. 100068, 2022.

FISTOURIS, J.; BERGH, C.; STRANDELL, A. Pregnancy of unknown location: external validation of the hcg-based m6np and m4 prediction models in an emergency gynaecology unit. **BMJ Open**, v. 12, n. 11, 2022.

GARZON, N. A.; BARBOSA, L. S. O. Aprendizado de Máquina na Medicina: Como Algoritmos de Aprendizado de Máquina Podem Ser Aplicados em Diagnósticos Médicos, Prognósticos e Descoberta de Novos Tratamentos. **RECIMA21 - Revista Científica Multidisciplinar**, v. 4, n. 12, 2023.

HEINRICH, B.; EICKHOFF, S. B. Your evidence? Machine learning algorithms for medical diagnosis and prediction. **Human Brain Mapping**, v. 41, n. 6, p. 1435-1444, 2020.

KITCHENHAM, B. **Procedures for Performing Systematic Reviews**. Keele University, UK: Department of Computer Science, 2004. Technical Report TR/SE-0401.

MA, D.; YANG, R.; CHEN, Y. et al. Identification of noninvasive diagnostic biomarkers for ectopic pregnancy using data-independent acquisition (DIA) proteomics: a pilot study. **Scientific Reports**, v. 12, p. 19992, 2022.

MENNICKENT, D.; RODRÍGUEZ, A.; OPAZO, M.; RIEDEL, C.; CASTRO, E.; ERIZ-SALINAS, A.; APPEL-RUBIO, J.; AGUAYO, C.; DAMIANO, A.; GUZMÁN-GUTIÉRREZ, E.; ARAYA, J. Machine learning applied in maternal and fetal health: a narrative review focused on pregnancy diseases and complications. **Frontiers in Endocrinology**, v. 14, p. 1130139, 2023.

MULLANY, K.; MINNECI, M.; MONJAZEB, R.; COIADO, O. C. Overview of ectopic pregnancy diagnosis, management, and innovation. **Women's Health**, v. 19, p. 17455057231160349, 2023.

POON, A. I. F.; SUNG, J. J. Y. Opening the black box of AI-Medicine. **Journal of Gastroenterology and Hepatology**, v. 36, n. 3, p. 581-584, 2021.

RUEANGKET, P.; RITTILUECHAI, K.; PRAYOTE, A. Predictive analytical model for ectopic pregnancy diagnosis: statistics vs. machine learning. **Frontiers in Medicine**, v. 9, 2022.



REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

APLICAÇÃO DO APRENDIZADO DE MÁQUINA NO DIAGNÓSTICO DA GRAVIDEZ ECTÓPICA: UMA REVISÃO BIBLIOGRÁFICA
Pedro Clarindo Silva Neto, Rafael Kunst, Ricardo Francalacci Savaris

SAVARIS, R.; MAISSIAT, J.; MOL, B.; BARNHART, K.; LINK, C. Diagnosing ectopic pregnancy using the Bayes theorem, a classic that is good as new: a retrospective cohort study. **Human Reproduction**, v. 37, Supplement 1, p. deac107.410, 2022.

SHABAN, M.; MOLLAZADEH, S.; ESLAMI, S. et al. Prediction of chromosomal abnormalities in the screening of the first trimester of pregnancy using machine learning methods: a study protocol. **Reproductive Health**, v. 21, p. 101, 2024.

SHAZLY, S. A.; TRABUCO, E. C.; NGUFOR, C. G.; FAMUYIDE, A. O. Introduction to Machine Learning in Obstetrics and Gynecology. **Obstetrics & Gynecology**, v. 139, n. 4, p. 669-679, 2022.