

# APRENDIZAGEM DE MÁQUINA COMO MÉTODO AUXILIAR NA DETECÇÃO E PREVENÇÃO DO CÂNCER DE MAMA: REALIDADE E PERSPECTIVAS PARA O FUTURO

Andrezza Cristina da Silva Barros Souza; Ana Beatriz Dantas Souza, Clara Sales Gurgel Ribeiro Dantas; Maria Luiza França Guerra, Maria Luiza Gadelha Procópio Maranhão, Pedro Antonio Gomes Carvalho, Sarah Laini Lima Rodrigues de Azevedo, Suiane Miraele Oliveira de Souza, Williane Cristina de Oliveira Bernardino, Yasmin Eduarda Câmara de Carvalho, Ricardo Ney Cobucci (Dr.).

## Universidade Potiguar

Programa de Pós-Graduação em Biotecnologia, Natal, ricardo.cobucci@animaeducacao.com.br

### INTRODUÇÃO

O câncer de mama é a neoplasia mais incidente entre mulheres, sendo um desafio relevante para a saúde pública. O diagnóstico precoce é crucial, mas os métodos tradicionais apresentam limitações. Uma atenção especial da comunidade científica tem impulsionado o desenvolvimento de algoritmos e sistemas de apoio ao diagnóstico baseados em Aprendizado de Máquina (AM) (GUPTA; GARG, 2020). Essas ferramentas não apenas aumentam a precisão dos exames, mas também permitem a identificação precoce de pacientes com maior risco de desenvolver a doença.

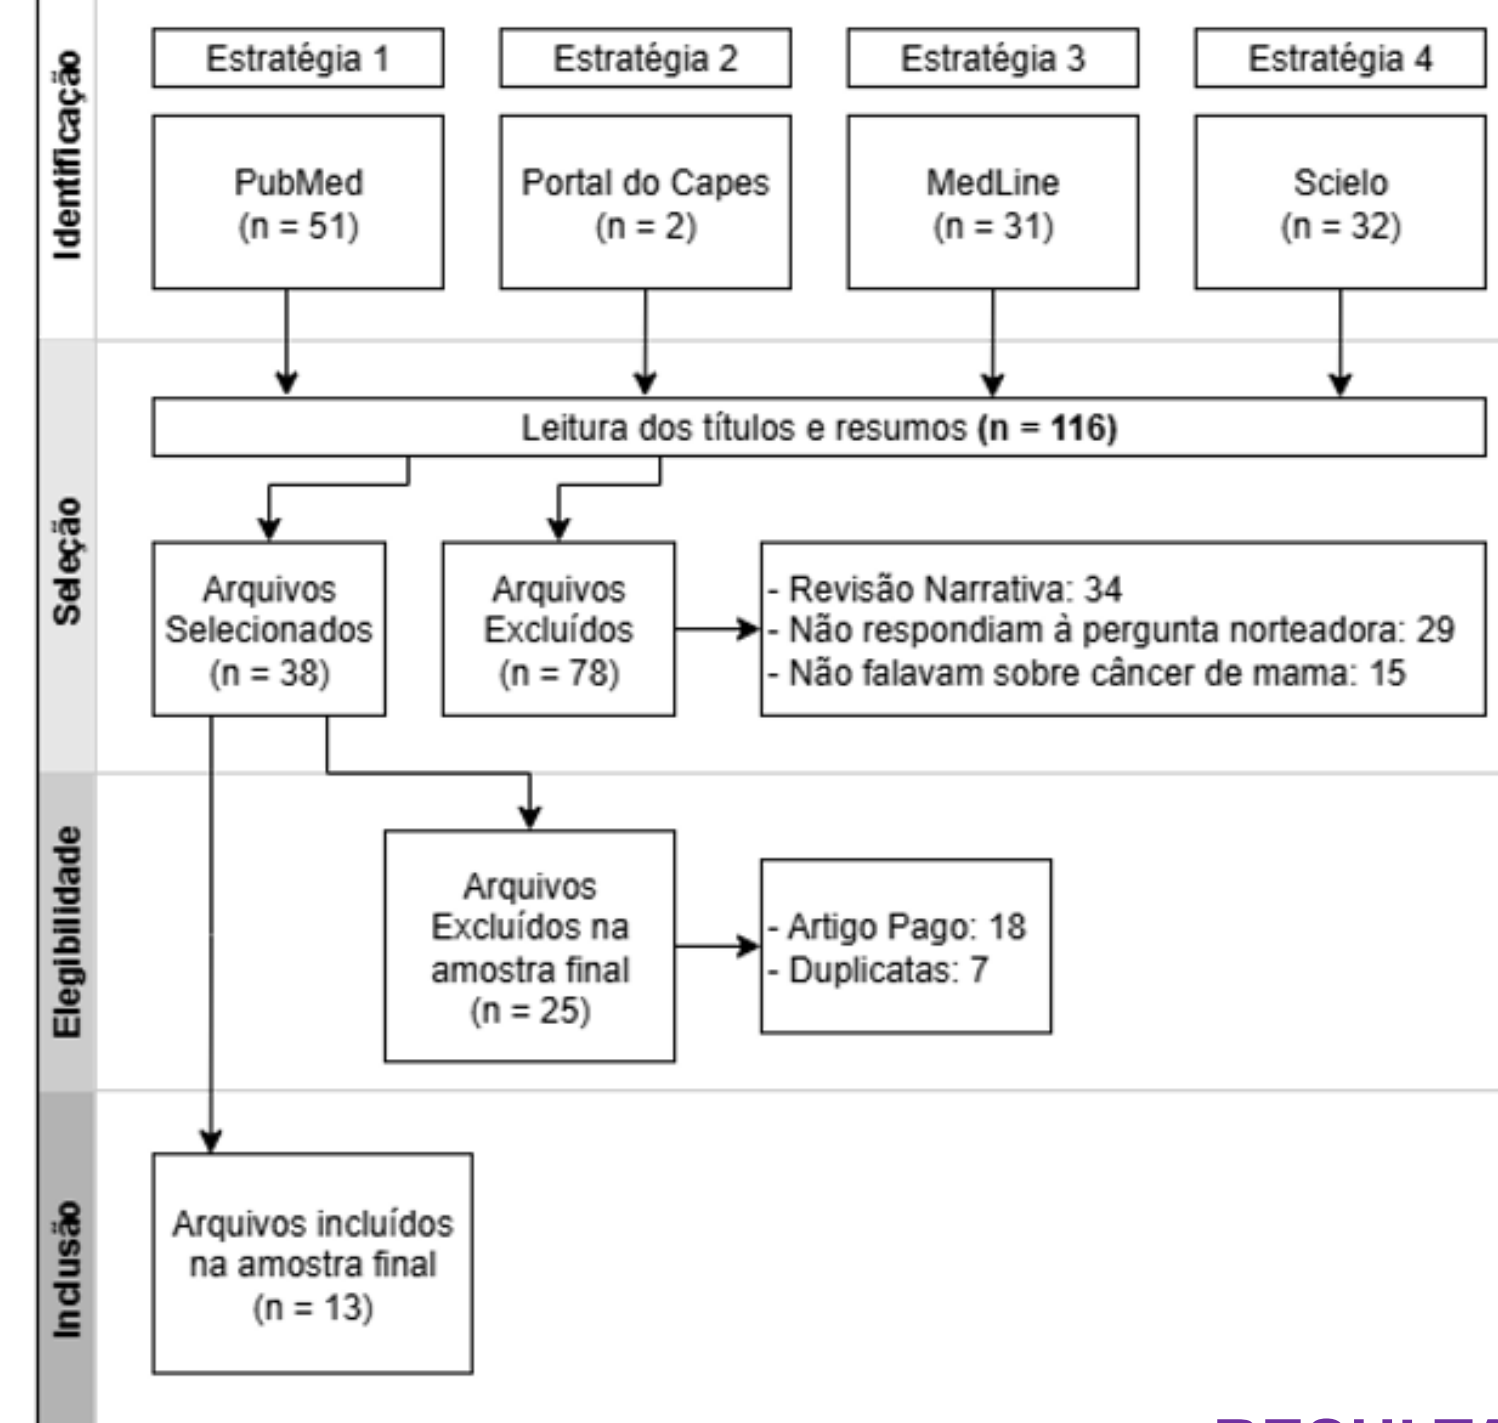
### OBJETIVOS

Esta revisão de literatura tem como objetivo analisar os avanços na aplicação de técnicas de AM na detecção, diagnóstico e prognóstico do câncer de mama, destacando os principais métodos utilizados, os resultados obtidos e os desafios para sua implementação clínica.

### METODOLOGIA

Esta revisão de literatura foi conduzida com o objetivo de identificar e analisar estudos publicados entre 2019 e 2024 que abordam a aplicação de técnicas de aprendizado de máquina na prevenção e detecção do câncer de mama.

Figura 1 - O Diagrama descritivo das etapas de identificação dos estudos elegíveis.



Foram utilizados descritores padronizados do Medical Subject Headings (MeSH) combinados por operadores booleanos. Os termos aplicados foram: ("breast neoplasms"[MeSH Terms] AND ("artificial intelligence"[MeSH Terms] OR "machine learning"[MeSH Terms])) AND (((("cancer screening"[MeSH Terms] OR "mammography"[MeSH Terms] OR "ultrasonography, mammary"[MeSH Terms] OR "prognosis"[MeSH Terms]). A seleção dos artigos seguiu critérios de elegibilidade previamente estabelecidos, considerando a relevância metodológica e o alinhamento com o objetivo desta revisão, conforme apresentados na Figura 1.

### RESULTADOS

Diversos estudos têm demonstrado que essas tecnologias podem tornar o diagnóstico mais preciso, reduzir a necessidade de biópsias invasivas e oferecer melhores previsões sobre a evolução da doença, esses estudos reforçam o papel da inteligência artificial como aliada no rastreamento mamográfico, destacando que algoritmos de IA têm contribuído para reduzir falsos positivos e negativos, aumentando a confiabilidade dos exames. Os estudos apresentaram ferramentas conseguem identificar tumores não detectados por métodos convencionais, atuando como um suporte eficaz para radiologistas (Tabela 1).

Tabela 1. A tabela comparativa dos artigos

Estudo e ano	Técnicas de machine leaning	Resultados	Principais achados
Hickman <i>et al.</i> (2022)	Redes convolucionais	<b>Algoritmo:</b> Curva AUC - 0,86 Sensibilidade - 80,4% Especificidade - 82,1% <b>Leitor:</b> Curva AUC - 0,84 Sensibilidade - 78,5% Especificidade - 82,6% <b>Algoritmos independentes</b> Curva AUC - 0.81 à 0.97 Sensibilidade - 0.52 à 0.96 Especificidade - 0.41 à 0.46 <b>Radiologistas auxiliados por IA</b>	As análises implicam que existe melhoria no diagnóstico e predição do câncer de mama em comparação com a verificação somente humana.
Anderson <i>et al.</i> (2022)	Redes convolucionais	Curva AUC - Ø Sensibilidade - 0.69 à 0.89 Especificidade - 0.74 à 0.98 <b>Combinação de modelos de IA</b> Curva AUC - 0.90 à 0.92 Sensibilidade - 0.87 Especificidade - 0.92	5 estudos demonstraram que a combinação do diagnóstico de radiologistas com auxílio de inteligências artificiais aumentou a acurácia desses desfechos, 3 mostram que a acurácia de diagnóstico se mostra superior à de radiologistas e 2 apontam menor acurácia para inteligências artificiais independentes.
Freeman <i>et al.</i> (2021)	CNN (Deep Learning), ANN (tradicional), Outros ML supervisionados	Curva AUC > 0,90 Acurácia - 75 - 85% Sensibilidade - 82 - 96% Especificidade - 78 - 96%	CNNs aplicadas a mamografia têm desempenho semelhante ou superior a radiologistas, mas reforça que ainda não há evidência suficiente para substituir a dupla leitura padrão em rastreamento de câncer de mama. ANNs tradicionais e ML clássicos ficaram abaixo disso.

Além de auxiliar no diagnóstico, o aprendizado de máquina tem sido explorado como ferramenta para prever o risco de desenvolvimento e progressão do câncer de mama, utilizando mamografias anteriores para distinguir entre evoluções benignas e malignas .

Os resultados mostraram desempenho estatisticamente significativo, quando combinadas técnicas de radiômica e redes neurais convolucionais, embora classificadores mais simples,



Tabela 2. A tabela comparativa dos artigos

Estudo e Ano	Técnica de Machine learning (ML)	Separação dos dados em treino e teste	Curva AUC, ROC ou acurácia (ML x leitor)	Sensibilidade (ML x Leitor)	Especificidade (ML x Leitor)
Watanabe <i>et al.</i> (2019)	cmAssist™ (AI-CAD)	-	ML: AI-CAD: AUC = 0.815 Leitor: -	ML: até 98% Leitor: 51% (média)	ML: - Leitor: -
Duggento <i>et al.</i> (2019)	Rede neural convolucional (CNN)	68,3% treino 9,4% validação 22,3% teste	ML Modelo 1 AUC = 0.785 ML Modelo 2 AUC = 0.774 Leitor: -	ML Modelo 1: 84.4 % ML Modelo 2: até 99.7% Leitor: -	ML Modelo 1: 62.4% ML Modelo 2: 28.6% Leitor: -
Chen <i>et al.</i> (2023)	YOLO-AMDF + MLP	80% treino 20% teste	ML: AUC = 0.888 Leitor: -	ML: 88.4% Leitor: -	ML:80.8% Leitor: -
Albadr <i>et al.</i> (2023)	Fast Learning Network (FLN)	70% treino 30% teste	ML WBCD: ROC = 0.993 ML WDBC: ROC = 0.984 Leitor: ROC = 0,911	ML WBCD: 99.40% ML WDBC: 96.81% Leitor: -	ML WBCD: 97.85% ML WDBC: 96.96% Leitor: -
Li <i>et al.</i> (2023)	LSTM - Long Short-Term Memory, SVM - Support Vector Machine	-	ML: AUC = 0.60-0.65 Leitor: -	ML: - Leitor: -	ML: - Leitor: -
Meng <i>et al.</i> (2023)	Deep Learning (EfficientNet-B3 CNN)	75% treino 25% teste	ML: AUC = 0,952 Leitor: AUC = 0,895	ML: 93,5% Leitor: 88,7%	ML: 89,1% Leitor: 82,4%
Alhussan <i>et al.</i> (2023)	CNN otimizado com algoritmo ABER + AlexNet (Transfer Learning)	70% treino 30% teste	Acurácia 97,95%	ML: 0,965 - 0,972 (Dataset-1) 0,970 - 0,993 (Dataset-2) Leitor: -	ML: 0,375 - 0,945 (Dataset-1) 0,833 - 0,994 (Dataset-2) Leitor: -
González-Patiño <i>et al.</i> (2023)	AISAC-MMD	Utilizou 10 bases de dados médicas com validação cruzada (10-fold cross-validation)	Acurácia até 1.0	ML: - Leitor: -	ML: - Leitor: -
Haji Maghsoudi <i>et al.</i> (2021)	Deep-LIBRA – (pipeline): CNN, ResNet, MLRadiômico, SVMs e regressão logística.	70% treino/ validar 30% para teste	ML Percent Density AUC = 0.612 ML: Dense AUC = 0.642 ML (ensemble SVM): AUC = 0.578 (não ajustado) 0.582 (ajustado idade e IMC) Leitor: - Acurária 80.3%	ML: - Leitor: -	ML: - Leitor: -
Lamy <i>et al.</i> (2019)	CBR, kNN, WkNN, RBIA, MDS	-		ML: - Leitor: -	ML: - Leitor: -

como SVM, tenham apresentado desempenho próximo ao acaso. Apesar das limitações metodológicas, como ausência de métricas clássicas e comparações estatísticas adicionais, o estudo reforça o potencial clínico de abordagens agregadas. No campo regulatório e ético, há lacunas sobre responsabilidade em erros diagnósticos e confiança dos pacientes. Em síntese, a literatura reconhece a IA como ferramenta promissora para reduzir variabilidade e otimizar fluxos, mas destaca a necessidade de validações multicêntricas e avaliações éticas, econômicas e sociais antes de sua adoção ampla.

### CONCLUSÕES

As evidências apresentam que a IA e o AM estão transformando a forma como enfrentamos o câncer de mama. Desde a leitura automatizada de mamografias até a previsão da progressão tumoral, essas tecnologias têm contribuído para diagnósticos mais precisos, redução de procedimentos invasivos e melhor identificação de pacientes em risco. No entanto, para que esses avanços cheguem de fato à prática clínica, ainda é preciso superar obstáculos importantes. A dificuldade de interpretar os modelos de IA, a escassez de validações clínicas robustas e a falta de estudos em populações diversas limitam sua aplicação em larga escala. Além disso, compreender o impacto real dessas ferramentas na vida das pacientes — como a redução da mortalidade ou a melhoria da qualidade de vida — exige pesquisas de longo prazo. A integração de dados genômicos, clínicos e de imagem em modelos mais completos é uma das promessas para o futuro da oncologia personalizada.

### BIBLIOGRAFIA

ANDERSON, A. W. *et al.* Independent External Validation of Artificial Intelligence Algorithms for Automated Interpretation of Screening Mammography: A Systematic Review. **Journal of the American College of Radiology**, v. 19, n. 2, p. 259–273, 2022.

FREEMAN, K.; *et al.* Use of artificial intelligence for image analysis in breast cancer screening programmes: systematic review of test accuracy. **BMJ**, p. n1872, 2021.

HICKMAN, S. E. *et al.* Machine Learning for Workflow Applications in Screening Mammography: Systematic Review and Meta-Analysis. **Radiology**, v. 302, p. 88–104, 2022.

DEMBROWER, K. *et al.* Effect of artificial intelligence-based triaging of breast cancer screening mammograms on cancer detection and radiologist workload: a retrospective simulation study. **The Lancet Digital Health**, v. 2, n. 9, p. e468–e474, set. 2020.