

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

AUTORES:

Andrezza Cristina da Silva Barros Souza¹ (andrezza.barros@gmail.com); Ana Beatriz Dantas Souza¹; Clara Sales Gurgel Ribeiro Dantas¹; Maria Luiza França Guerra¹, Maria Luiza Gadelha Procópio Maranhão¹, Universidade Potiguar; Pedro Antonio Gomes Carvalho²; Sarah Laini Lima Rodrigues de Azevedo; Suiane Miraele Oliveira de Souza¹; Williane Cristina de Oliveira Bernardino¹; Yasmin Eduarda Câmara de Carvalho¹; Ricardo Ney Cobucci¹ (Dr.)

¹Universidade Potiguar – UnP, Natal – RN.

²Universidade São Judas Tadeu – USJT, São Paulo – SP.

RESUMO

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. Esta revisão de literatura analisou estudos entre 2019 e 2024 nas bases PubMed, Periódicos Capes e SciELO, focando na aplicação do aprendizado de máquina (AM) no diagnóstico e prognóstico da doença. As técnicas de AM, como redes neurais profundas e aprendizado por transferência, demonstraram alta acurácia na classificação de imagens mamográficas, reduzindo falsos diagnósticos e a necessidade de procedimentos invasivos. A inteligência artificial tem contribuído para otimizar exames de rastreamento, aumentando a precisão e reduzindo a variabilidade entre radiologistas. Apesar dos avanços, persistem desafios como a interpretabilidade dos modelos e a validação clínica. Conclui-se que o AM representa um avanço promissor, exigindo esforços contínuos para sua incorporação segura na prática clínica..

Palavras-chave: Inteligência artificial; Diagnóstico precoce; Aprendizagem profunda.

INTRODUÇÃO

O câncer de mama é a neoplasia mais prevalente entre mulheres, representando um desafio crítico para a saúde pública global (SUNG et al., 2021). Com mais de 2,3 milhões de novos casos anuais, representando 24,5% do total,

estratégias eficazes de diagnóstico precoce são essenciais para aumentar as taxas de sobrevivência. No entanto, os métodos convencionais enfrentam limitações como alta taxa de falsos positivos e negativos, além da variabilidade na interpretação de imagens. Nesse cenário, a inteligência artificial (IA) e o aprendizado de máquina (AM) emergem como ferramentas promissoras para aprimorar a acurácia diagnóstica e a predição prognóstica, melhorando a predição clínica e reduzindo erros (TRISTER; BUIST; LEE, 2017).

O câncer de mama tem recebido atenção especial da comunidade científica, impulsionando o desenvolvimento de algoritmos e sistemas de apoio ao diagnóstico baseados em 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. No entanto, apesar dos avanços, ainda existem lacunas significativas na literatura, como a necessidade de estudos que validem esses modelos em populações diversas e em cenários clínicos reais.


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.

MÉTODO

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. Foram incluídos artigos nos idiomas inglês e português que tratassem especificamente da utilização de inteligência artificial (IA) e aprendizado de máquina (AM) no diagnóstico precoce e no prognóstico dessa neoplasia. A pesquisa foi conduzida nas bases PubMed, Periódicos Capes, MedLine e SciELO. 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.

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



Após triagem, aplicação dos critérios de exclusão (Tabela 1) e leitura crítica, 13 estudos foram incluídos, conforme critérios de elegibilidade metodológica e relevância temática

Tabela 1. Critérios de exclusão

Critério de exclusão	Artigos excluídos
Revisão Narrativa	34
Não respondiam à pergunta norteadora	29
Artigo Pago	18
Não falava sobre câncer de mama	15
Duplicatas	7

RESULTADOS E DISCUSSÃO

Diversos estudos têm demonstrado que a IA e o AM podem tornar o diagnóstico mais preciso, reduzir a necessidade de biópsias invasivas e oferecer melhores previsões sobre a evolução da doença. A detecção precoce, essencial para aumentar as chances de cura, tem se beneficiado especialmente da aplicação de algoritmos capazes de interpretar imagens mamográficas com alto grau de

acurácia.

Aplicação de Inteligência Artificial no Diagnóstico do Câncer de Mama

Nesse cenário, Anderson et al. (2022) validaram modelos de IA que alcançaram desempenho comparável ao de radiologistas experientes, reforçando o potencial dessas ferramentas no apoio ao diagnóstico. Já Hickman et al. (2022) destacaram a sobrecarga enfrentada por profissionais da radiologia, que frequentemente realizam dupla leitura de mamografias. A introdução de algoritmos, especialmente os baseados em redes neurais convolucionais, surge como uma solução viável para ampliar a capacidade de análise dos exames, mantendo — e até elevando — a qualidade diagnóstica, conforme apresentado na Tabela 2.

Tabela 2. A tabela comparativa dos artigos revisados.

Estudo e ano	Técnicas de machine learning	Resultados	Principais achados
Hickman <i>et al.</i> (2022)	Redes neurais convolucionais	Algoritmo: Curva AUC - 0,86 Sensibilidade - 80,4% Especificidade - 82,1% Leitor: Curva AUC - 0,84 Sensibilidade - 78,5% Especificidade - 82,6%	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 neurais convolucionais	Algoritmos independentes Curva AUC - 0,81 à 0,97 Sensibilidade - 0,52 à 0,96 Especificidade - 0,41 à 0,46 Radiologistas auxiliados por IA Curva AUC - Ø Sensibilidade - 0,69 à 0,89 Especificidade - 0,74 à 0,98 Combinação de modelos de IA 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.

Estudos recentes reforçam o papel da inteligência artificial como aliada no rastreamento mamográfico. Freeman et al. (2021) destacaram que algoritmos de IA têm contribuído para reduzir falsos positivos e negativos, aumentando a confiabilidade dos exames. Watanabe et al. (2019) foram além, mostrando que essas ferramentas conseguem identificar tumores não detectados por métodos convencionais, atuando como um suporte eficaz para radiologistas.

Avanços também foram observados na classificação de lesões mamárias. Duggento et al. (2019) desenvolveram uma arquitetura de deep learning capaz de distinguir lesões malignas e benignas com alta precisão. Chen et al. (2023), por sua vez, aplicaram o modelo YOLO para identificar calcificações suspeitas, aprimorando a detecção de sinais de malignidade. Já Albadr et al. (2023) propuseram um classificador baseado no algoritmo FLN, validado em dois bancos de dados distintos. Os resultados mostraram desempenho robusto, com destaque para o banco WBCD, onde o modelo apresentou métricas ligeiramente superiores, evidenciando sua consistência diagnóstica.

Predição do Risco e da Progressão do Câncer de Mama

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. Li et al. (2023) investigaram essa aplicação por meio de modelos temporais (LSTM), utilizando mamografias anteriores para distinguir entre evoluções benignas e malignas (Tabela 3). Os resultados mostraram desempenho estatisticamente significativo, quando combinadas técnicas de radiômica e redes neurais convolucionais, embora classificadores mais simples, 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.

Complementando essa perspectiva, Haji Maghsoudi et al. (2021) desenvolveram o modelo Deep-LIBRA, voltado para a quantificação da densidade mamária — um fator de risco relevante. Validado de forma independente, o sistema demonstrou aplicabilidade na estratificação de risco, contribuindo para decisões mais personalizadas e eficazes na prevenção do câncer de mama.

Tabela 3. Tabela comparativa de dados dos artigos selecionados.

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: -	ML: - Leitor: -	ML: - Leitor: -
Lamy <i>et al.</i> (2019)	CBR, kNN, WkNN, RBIA, MDS	-	Acurácia 80.3%	ML: - Leitor: -	ML: - Leitor: -

Redução de Procedimentos Invasivos e Otimização da Classificação Tumoral

A IA também tem sido aplicada para reduzir a realização de biópsias desnecessárias, um dos desafios do diagnóstico do câncer de mama. Meng et al. (2023) utilizaram aprendizado de transferência para diferenciar lesões BI-RADS 4, reduzindo significativamente o número de biópsias recomendadas sem comprometer a sensibilidade diagnóstica. Alhussan et al. (2023) desenvolveram um modelo baseado na otimização do raio terrestre de Al-Biruni para classificação de câncer de

mama, utilizando aprendizado de transferência e obtendo elevada precisão na diferenciação entre tumores benignos e malignos. A abordagem proposta foi avaliada por meio dos dois conjuntos de dados públicos, com uma precisão de classificação média de 97,95% sendo alcançada.

Outro estudo relevante foi conduzido por González-Patiño et al. (2023), que propuseram o AISAC-MMD para classificação com dados mistos e incompletos, avaliando desempenho por acurácia balanceada (média dos recalls por classe). O método mostrou resultados altos em várias bases de mama, em bases mais desafiadoras, como LCDS (0,688) e BCDS (0,731), o AISAC-MMD foi competitivo, embora C4.5 tenha superado pontualmente (MMDS 0,823 vs. 0,797; BCDS 0,741 vs. 0,731). No conjunto, o algoritmo proposto lidera a maioria das bases, com evidência de superioridade estatística frente a diversos baselines. Esses resultados sugerem melhor discriminação em cenários reais com dados heterogêneos, potencialmente contribuindo para diminuir indicações desnecessárias de procedimentos quando integrado a fluxos diagnósticos robustos. O estudo não reporta sensibilidade, especificidade ou acurácia simples; portanto, não é possível quantificar, a partir dele, o trade-off de falso-positivos/falso-negativos (crítico para estimar impacto direto em biópsias evitadas).

Os resultados desta revisão confirmam que o uso de técnicas de aprendizado de máquina (ML) no diagnóstico do câncer de mama tem alcançado alta precisão e eficiência. Modelos híbridos como LightGBM, Perceptron Multicamadas e Máquinas de Vetores de Suporte atingem acurácia de até 98% (Moura Filho et al., 2014), enquanto redes neurais e KNN superam 90% na distinção entre nódulos benignos e malignos (Dallagassa & Oliveira, 2024).

A incorporação de ML pode transformar o rastreamento e o diagnóstico precoce, aumentando sensibilidade e especificidade e reduzindo a variabilidade entre profissionais (McKinney et al., 2020; Dietze et al., 2022). Sistemas de IA já demonstram desempenho equivalente ou superior ao de radiologistas (McKinney et al., 2020), otimizando o fluxo clínico (Dembrower et al., 2020). Modelos de deep learning aplicados à tomossíntese melhoram a detecção e reduzem a variabilidade interobservador, elevando a taxa de detecção e reduzindo falsos positivos (Houssami et al., 2019).

Estudos multicêntricos e de longo prazo em populações diversas ainda são

necessários para validação (Hussain et al., 2024). Embora alguns algoritmos superem radiologistas (Hickman et al., 2022; Anderson et al., 2022), ainda não há evidências suficientes para substituir a dupla leitura padrão (Freeman et al., 2021), reforçando o papel da IA como apoio à decisão médica.

A interpretabilidade dos modelos de deep learning permanece um desafio, sendo a falta de transparência um fator de resistência (Lamy et al., 2019). Barreiras práticas incluem interoperabilidade, padronização de dados, custos e capacitação, o que pode ampliar desigualdades de acesso. Além disso, faltam estudos que avaliem o impacto clínico de longo prazo e considerem variáveis como etnia e densidade mamária.

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 (McKinney et al., 2020; Dembrower et al., 2020), mas destaca a necessidade de validações multicêntricas e avaliações éticas, econômicas e sociais antes de sua adoção ampla.

CONCLUSÃO

As evidências reunidas nesta revisão mostram que a inteligência artificial e o aprendizado de máquina 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.

FOMENTO

O trabalho teve a concessão de Bolsa Voluntária de Iniciação Científica pelo PROCIÊNCIA do Programa Ânima, e do Programa de Pós-Graduação em Biotecnologia (PPGBio) da Universidade Potiguar (UnP).

REFERÊNCIAS

- ALBADR, M. A. A. *et al.* Breast cancer diagnosis using the fast learning network algorithm. **Frontiers in Oncology**, v. 13, 2023.
- ALHUSSAN, A. A. *et al.* Classification of Breast Cancer Using Transfer Learning and Advanced AI-Biruni Earth Radius Optimization. **Biomimetics**, v.8, n.3, p.270, 2023.
- 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.
- CHEN, J.-L. *et al.* A YOLO-based AI system for classifying calcifications on spot magnification mammograms. **BioMedical Engineering OnLine**, v. 22, n. 1, p. 54, 2023.
- DALLAGASSA, M. R.; DE OLIVEIRA, A. J. C. Uso de machine learning no diagnóstico de câncer de mama através de ultrassonografia. **Journal of Health Informatics**, v. 16, n. Especial, 19 nov. 2024.
- 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.
- DIETZE, M. M. A. *et al.* A compact and mobile hybrid C-arm scanner for simultaneous nuclear and fluoroscopic image guidance. **European Radiology**, v.32, n.1, p.517–523, 16 jan. 2022.
- DUGGENTO, A. *et al.* An Ad Hoc Random Initialization Deep Neural Network Architecture for Discriminating Malignant Breast Cancer Lesions in Mammographic Images. **Contrast Media & Molecular Imaging**, v. 2019, p. 1–9, 22 maio 2019.
- 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.
- GONZÁLEZ-PATÍÑO, D. *et al.* A Novel Bioinspired Algorithm for Mixed and Incomplete Breast Cancer Data Classification. **International Journal of Environmental Research and Public Health**, v. 20, n. 4, p. 3240, 13 fev. 2023.
- HAJI MAGHSOUDI, O. *et al.* Deep-LIBRA: An artificial-intelligence method for robust quantification of breast density with independent validation in breast cancer risk assessment. **Medical Image Analysis**, v. 73, p. 102138, 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.

HOUSSAMI, N. *et al.* Artificial Intelligence (AI) for the early detection of breast cancer: a scoping review to assess AI's potential in breast screening practice. **Expert Review of Medical Devices**, v. 16, n. 5, p. 351–362, 4 maio 2019.

HUSSAIN, S. *et al.* Breast cancer risk prediction using machine learning: a systematic review. **Frontiers in Oncology**, v. 14, 20 mar. 2024.

LAMY, J.-B. *et al.* Explainable artificial intelligence for breast cancer: A visual case-based reasoning approach. **Artificial Intelligence in Medicine**, v. 94, p. 42–53, 2019.

LI, H. *et al.* Temporal Machine Learning Analysis of Prior Mammograms for Breast Cancer Risk Prediction. **Cancers**, v. 15, n. 7, p. 2141, 2023.

MCKINNEY, S. M. *et al.* International evaluation of an AI system for breast cancer screening. **Nature**, v. 577, n. 7788, p. 89–94, 2 jan. 2020.

MENG, M. *et al.* Reducing the number of unnecessary biopsies for mammographic BI-RADS 4 lesions through a deep transfer learning method. **BMC Medical Imaging**, v. 23, n. 1, p. 82, 2023.

MOURA FILHO, J. O. F. *et al.* Detecção de câncer de mama por imagem com classificador híbrido. **Journal of Health Informatics**, v. 16, n. Especial, 19 nov. 2024.

SUNG, H. *et al.* Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries. **CA: A Cancer Journal for Clinicians**, v. 71, n. 3, p. 209–249, 4 maio 2021.

WATANABE, A. T. *et al.* Improved Cancer Detection Using Artificial Intelligence: a Retrospective Evaluation of Missed Cancers on Mammography. **Journal of Digital Imaging**, v. 32, n. 4, p. 625–637, 2019.