

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

MACHINE LEARNING AS AN AID TO BREAST CANCER DETECTION AND PREVENTION: REALITY AND FUTURE PROSPECTS

DOI: 10.16891/2317-434X.v13.e3.a2025.id2793

Recebido em: 21.02.2025 | Aceito em: 02.10.2025

Andrezza Cristina da Silva Barros Souza^a, Gabriela Chacon Barbosa^a, Isabela da Costa Ferreira^a, Maira Ivze Bezerra Alves^a, Pedro Antonio Gomes Carvalho^b, Maria Luiza Gadelha Procópio Maranhão^a, Ricardo Ney Cobucci^{a*}

Universidade Potiguar – UnP, Natal – RN, Brasil^a
Universidade São Judas Tadeu – USJT, São Paulo – SP, Brasil^b
*E-mail: ricardo.cobucci.737@ufrn.edu.br

RESUMO

O câncer de mama é um dos principais desafios da saúde pública global, destacando-se como a neoplasia de maior incidência entre as mulheres. O diagnóstico precoce é essencial para aumentar as taxas de sobrevida, mas os métodos tradicionais apresentam limitações como alta taxa de falsos positivos e negativos. Nesse contexto, o aprendizado de máquina (AM) surge como uma ferramenta promissora para aprimorar a detecção e o prognóstico da doença. Esta revisão de literatura analisou estudos publicados entre 2019 e 2024 nas bases PubMed, Periódicos Capes e SciELO, utilizando descritores específicos relacionados ao câncer de mama e AM. Os resultados apontam que técnicas de AM, como redes neurais profundas e aprendizado de transferência, demonstram elevada acurácia na classificação de imagens mamográficas, reduzindo a necessidade de procedimentos invasivos e melhorando a predição do risco de câncer. Além disso, a inteligência artificial tem sido aplicada para otimizar os exames de rastreamento, aumentando a precisão diagnóstica e minimizando a variabilidade entre os radiologistas. No entanto, desafios como a interpretabilidade dos modelos e a necessidade de validação clínica robusta ainda persistem. Conclui-se que o aprendizado de máquina representa um avanço significativo no diagnóstico e prognóstico do câncer de mama, mas esforços contínuos são necessários para sua plena integração na prática clínica.

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

ABSTRACT

Breast cancer is one of the main global public health challenges, standing out as the neoplasm with the highest incidence among women. Early diagnosis is essential to increase survival rates; however, traditional methods face limitations such as a high false positive and false-negative. In this context, machine learning (ML) emerges as a promising tool for improving disease detection and prognosis. This literature review analysed studies published between 2019 and 2024 in the PubMed, Periódicos Capes, and SciELO databases, using specific descriptors related to breast cancer and ML. The findings indicate that ML techniques, such as deep neural networks and transfer learning, demonstrate high accuracy in classifying mammographic images, reducing the need for unnecessary biopsies, and improving cancer risk prediction. In addition, artificial intelligence has been applied to optimise screening exams, increasing diagnostic accuracy and minimizing variability between radiologists. However, challenges such as interpretability of the models and the need for robust clinical validation still remain. It is concluded that machine learning represents a significant advance in breast cancer diagnosis and prognosis, but continuous efforts are needed for its full integration into clinical practice.

Keywords: Machine Learning; Breast neoplasms; Artificial intelligence; Deep learning.

INTRODUÇÃO

O câncer é um dos maiores desafios da saúde pública global, sendo uma das principais causas de morte e um fator limitante para o aumento da expectativa de vida em todo o mundo (SUNG *et al.*, 2021). Entre os tipos de carcinomas que afetam as mulheres, o câncer de mama se destaca como o mais prevalente, com 2,3 milhões de novos casos anuais, representando 24,5% do total. Em seguida, aparecem os cânceres de colôn e reto (9,4%), pulmão (8,4%), colo do útero (6,5%) e pele não melanoma (5,2%) (SUNG *et al.*, 2021). Essa alta incidência reforça a necessidade de estratégias eficazes para o diagnóstico precoce e o tratamento adequado.

O diagnóstico do câncer de mama envolve uma série de etapas, desde a obtenção de imagens digitais até a segmentação da região de interesse e a classificação das lesões (GONZÁLEZ-PATIÑO *et al.*, 2023). No entanto, esse processo enfrenta desafios significativos, como a variabilidade na interpretação das imagens e as altas taxas de falsos positivos e negativos, que podem chegar a 20% dos diagnósticos (DUGGENTO *et al.*, 2019). Essas limitações destacam a urgência de métodos mais precisos e confiáveis para auxiliar os profissionais de saúde.

Nesse contexto, a inteligência artificial (IA) e o aprendizado de máquina (AM), ou *machine learning* (ML), emergem como tecnologias promissoras, pois com o avanço da tecnologia da informação na saúde e o crescimento exponencial dos dados médicos, os algoritmos de AM têm demonstrado potencial para identificar padrões ocultos em grandes conjuntos de dados, melhorando a predição clínica e reduzindo erros diagnósticos (TRISTER; BUIST; LEE, 2017). Esses modelos podem explorar relações complexas entre casos históricos, auxiliando na minimização de falsos positivos e negativos (MONTAZERI; MONTAZERI; MONTAZERI; BEIGZADEH, 2016).

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.

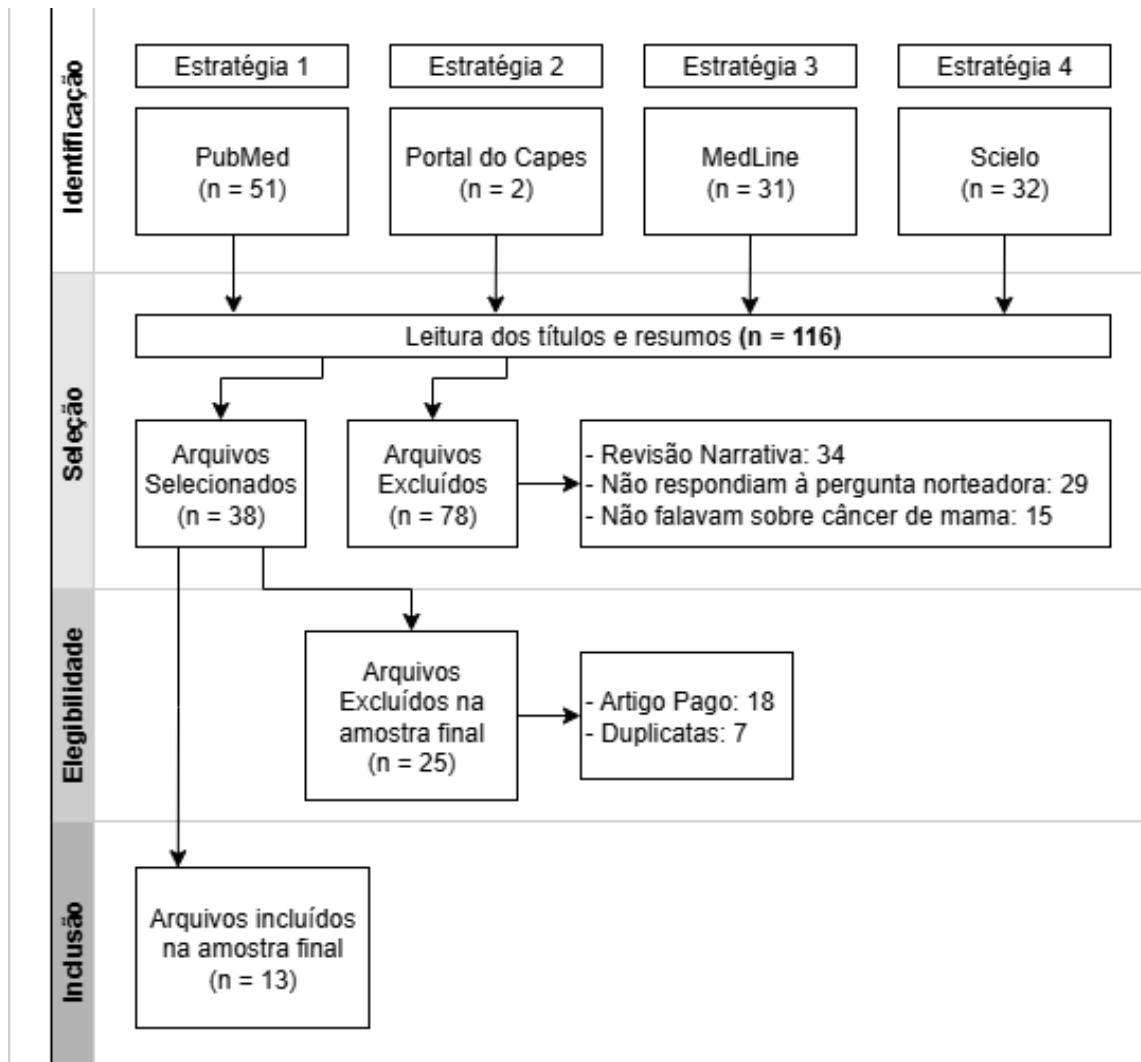
Assim, esta revisão tem como objetivo mapear os avanços na aplicação do aprendizado de máquina na prevenção e no diagnóstico do câncer de mama, identificando os principais métodos desenvolvidos, os resultados alcançados e as lacunas que ainda precisam ser exploradas. Além disso, ao sintetizar o conhecimento existente, este trabalho visa fornecer insights para futuras pesquisas e contribuir para a incorporação efetiva dessas tecnologias na prática 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. Foram incluídos artigos nos idiomas inglês e português que tratasse especificamente da utilização de inteligência artificial (IA) e aprendizado de máquina (AM) no diagnóstico precoce e no prognóstico dessa neoplasia. As buscas foram realizadas nas bases de dados PubMed, Periódicos Capes, MedLine e SciELO, garantindo uma ampla cobertura da produção científica relevante ao tema.

Para a recuperação dos estudos, utilizaram-se descritores padronizados do Medical Subject Headings (MeSH), combinados por meio de operadores booleanos, a fim de refinar os resultados e garantir inclusões relevantes. 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 a busca nas bases de dados, foram selecionados 116 artigos. Com a leitura de títulos e resumos, foram excluídos 78 artigos que não correspondiam ao tema principal em revisão, restando 38

artigos após essa etapa. Após leitura completa desses artigos, 13 estudos foram selecionados e incluídos nessa revisão.

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

A aplicação de algoritmos de machine learning e inteligência artificial na detecção, diagnóstico e prognóstico do câncer de mama tem sido amplamente estudada, com avanços significativos em diversas abordagens. As pesquisas analisadas indicam que técnicas de aprendizado de máquina podem aprimorar a precisão diagnóstica, reduzir a necessidade de biópsias invasivas e melhorar a predição da evolução da doença.

Aplicação de Inteligência Artificial no Diagnóstico do Câncer de Mama

A detecção precoce do câncer de mama é fundamental para aumentar as taxas de sobrevida das

pacientes, e a inteligência artificial tem se mostrado uma ferramenta promissora nesse contexto. Anderson *et al.* (2022) realizaram uma revisão sistemática que validou algoritmos de IA para interpretação automatizada de mamografias, destacando sua eficácia comparável à de radiologistas experientes.

Hickman *et al.* (2022) afirmaram que radiologistas encontram hoje na profissão o desafio de sobrecarga agravado pelas duas leituras usuais de mamografias. Dessa forma, a leitura auxiliada ou independente por algoritmos de inteligência artificial se torna uma alternativa para aumentar as leituras dos exames executados e melhorar acurácia diagnóstica. Essa revisão sistemática avaliou 14 estudos que utilizaram algum tipo de rede neural convolucional (Tabela 2).

Tabela 2. A tabela comparativa de artigos de modelo revisão sistemática.

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.

Resultados similares foram encontrados por Freeman *et al.* (2021), que revisaram a precisão da IA na

análise de imagens de rastreamento mamográfico, evidenciando a redução de falsos positivos e negativos.

Além disso, Watanabe *et al.* (2019) demonstraram que algoritmos de IA podem identificar cânceres que foram previamente não detectados em mamografias convencionais, sugerindo que essa tecnologia pode atuar como um suporte valioso para radiologistas.

Outro avanço significativo foi a utilização de redes neurais profundas para classificar lesões mamográficas. Duggento *et al.* (2019) propuseram uma arquitetura de deep learning com inicialização randômica para diferenciar lesões malignas e benignas, obtendo alta acurácia. Da mesma forma, Chen *et al.* (2023) desenvolveram um sistema baseado no modelo YOLO para a classificação de calcificações em mamografias ampliadas, aprimorando a identificação de padrões indicativos de malignidade. Albadr *et al.* (2023), propuseram um classificador diagnóstico para de câncer de mama baseado no algoritmo FLN utilizando dois bancos de dados WBCD e WDBC para o desenvolvimento e validação do modelo. A avaliação do desempenho do classificador foi realizada em diversas métricas, tendo sido validados por análise estatística média, erro quadrático médio e desvio padrão. A análise dos resultados demonstrou que o classificador obteve um desempenho robusto em ambos os bancos de dados, mas a performance no WBCD foi ligeiramente superior em quase todas as métricas avaliadas (Tabela 3).

Predição do Risco e da Progressão do Câncer de Mama

Além do diagnóstico, modelos de aprendizado de máquina têm sido utilizados para prever o risco de desenvolvimento e progressão do câncer de mama. Em Li *et al.* (2023), estudo de predição de risco a partir de mamografias prévias, modelos temporais (LSTM) mostraram discriminação acima do acaso para distinguir evoluções futuras malignas de benignas (Tabela 3). Em particular, houve desempenho significativo com radiômica da mama afetada ($AUC = 0,65$; $p=0,0042$) e com a combinação CNN+radiômica em ambas as mamas ($AUC = 0,65$; $p=0,0059$), enquanto um classificador de ponto único (SVM) permaneceu próximo ao acaso ($AUC = 0,52-0,55$; $p>0,34$). Não se observou diferença significativa entre treinar o LSTM com características extraídas por CNN ou radiômicas ($p=0,6511-0,8083$). Os autores observam ainda que, por relevância clínica, é útil considerar um classificador agregado entre mamas, mas

não realizaram comparação estatística adicional para preservar poder amostral. Este estudo não reporta acurácia, sensibilidade ou especificidade.

Em outra pesquisa, Haji Maghsoudi *et al.* (2021) propuseram o método Deep-LIBRA, baseado em inteligência artificial, para quantificar a densidade mamária e associá-la ao risco de câncer de mama. Esse modelo obteve validação independente, reforçando sua aplicabilidade clínica na estratificação de risco.

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).

Aplicações de IA Explicável e Métodos de Interpretação

Apesar do alto desempenho dos modelos de IA, sua interpretabilidade continua sendo um desafio. Nesse sentido, Lamy *et al.* (2019) avaliaram um sistema explicável de raciocínio baseado em casos aplicado ao câncer de mama. O desempenho foi reportado em acurácia (Tabela 3), e a sensibilidade e especificidade não foram

informadas, o que limita a estimativa do balanço entre falso-positivos e falso-negativos. Ainda assim, a combinação de explicabilidade visual e desempenho consistente em cenários heterogêneos sugere potencial para apoiar decisões clínicas e o acompanhamento longitudinal, desde que validado prospectivamente.

Além disso, Hickman *et al.* (2022) realizaram uma meta-análise sobre o uso de aprendizado de máquina na triagem mamográfica, destacando que modelos que incorporam explicabilidade são mais confiáveis e passíveis de aceitação por profissionais da saúde.

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 et al. (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 et al. (2019)	CBR, kNN, WkNN, RBIA, MDS	-	Acurácia 80.3%	ML: - Leitor: -	ML: - Leitor: -

DISCUSSÃO

Os resultados desta revisão de literatura evidenciam que a aplicação de técnicas de machine learning (ML) no diagnóstico do câncer de mama tem demonstrado alta precisão e eficiência. Estudos recentes destacam que modelos híbridos, combinando algoritmos como LightGBM, Perceptron Multicamadas (LPM) e Máquinas de Vetores de Suporte (MVS), alcançaram acurácia de até 98% na classificação de imagens de ultrassonografia mamária (MOURA FILHO; DA SILVA; GOMES; DE SOUZA; AMORA, 2014). Além disso, a utilização de redes neurais e algoritmos KNN apresentou taxas de assertividade superiores a 90% na distinção entre nódulos benignos e malignos (DALLAGASSA; DE OLIVEIRA, 2024).

A incorporação de ML na prática clínica pode revolucionar o rastreamento e o diagnóstico precoce do câncer de mama. Ferramentas baseadas em inteligência artificial (IA) têm o potencial de aumentar a sensibilidade e especificidade dos exames de imagem, reduzindo a variabilidade interobservador e auxiliando radiologistas na interpretação de mamografias e ultrassonografias (MCKINNEY *et al.*, 2020). Essa melhoria na acurácia diagnóstica pode levar a intervenções mais precoces e, consequentemente, a melhores prognósticos para as pacientes (DIETZE *et al.*, 2022).

Comparando com revisões anteriores, observa-se uma tendência consistente de aprimoramento nos modelos de ML aplicados para diagnóstico do câncer de mama. Por exemplo, McKinney *et al.* (2020) avaliaram um sistema de IA para triagem mamográfica que demonstrou desempenho equivalente ou superior ao de radiologistas experientes, sugerindo uma redução potencial na carga de trabalho dos profissionais de saúde (MCKINNEY *et al.*,

2020). Esses achados corroboram os resultados desta revisão, indicando que a IA pode servir como uma ferramenta complementar valiosa no contexto clínico.

Outra revisão relevante, conduzida por Dembrower *et al.* (2020), investigou o impacto da triagem baseada em IA na detecção do câncer de mama e na carga de trabalho dos radiologistas. Os autores concluíram que a implementação de sistemas de IA pode aumentar a taxa de detecção de cânceres e simultaneamente reduzir o número de mamografias a serem revisadas pelos radiologistas, otimizando o fluxo de trabalho e potencialmente melhorando os resultados para as pacientes (DEMBROWER *et al.*, 2020). Além disso, é importante contextualizar os resultados em relação a estudos recentes publicados sobre o tema. Por exemplo, um estudo analisou o impacto do deep learning na tomossíntese digital da mama, corroborando os achados desta revisão ao demonstrar que modelos de IA podem melhorar a detecção de lesões mamárias e reduzir a variabilidade interobservador (MOTA; CLARKSON; ALMEIDA; MATELA, 2022). Outra revisão, realizada por Houssami *et al.* (2019), avaliou a eficácia de sistemas de IA na triagem mamográfica e destacou que a integração dessas ferramentas pode aumentar a taxa de detecção de cânceres em até 5%, ao mesmo tempo em que reduz falsos positivos (HOUSSAMI; KIRKPATRICK-JONES; NOGUCHI; LEE, 2029). Esses estudos reforçam a consistência dos achados desta revisão, indicando que a IA e a aprendizagem de máquina têm potencial para transformar a prática clínica no rastreamento e diagnóstico do câncer de mama. No entanto, revisões anteriores também apontam para a necessidade de estudos multicêntricos e de longo prazo para validar a aplicabilidade clínica dessas tecnologias, especialmente em populações diversas e com

diferentes densidades mamárias (HUSSAIN *et al.*, 2024; RADAK; LAFTA; FALLAHI, 2023).

Estudos como os de Hickman *et al.* (2022) e Anderson *et al.* (2022) demonstram que algoritmos de IA apresentam desempenho semelhante ou até superior ao de radiologistas experientes, sobretudo quando utilizados como ferramenta de apoio. No entanto, revisões como a de Freeman *et al.* (2021) ressaltam que não há evidência suficiente para substituir a dupla leitura padrão em programas de rastreamento. Essa divergência revela uma tendência de convergência para modelos híbridos, nos quais a IA atua como suporte, mas não substitui a decisão médica.

Outro desafio crítico é a interpretação dos modelos de deep learning, frequentemente considerados “caixas-pretas”. Essa falta de transparência gera resistência entre profissionais de saúde e limita a confiança necessária para adoção em larga escala. Tentativas de introduzir métodos de IA explicável (Lamy *et al.*, 2019) apontam caminhos promissores, mas ainda insuficientes para garantir ampla aceitação clínica.

Do ponto de vista prático, a implementação enfrenta barreiras de interoperabilidade entre sistemas hospitalares, além da necessidade de padronização na coleta e processamento de imagens médicas. Essas limitações dificultam a integração dos algoritmos em fluxos clínicos reais, sobretudo em instituições com infraestrutura tecnológica limitada. Ademais, os custos de implantação e manutenção de plataformas baseadas em IA, associados à exigência de treinamento contínuo de radiologistas e técnicos, podem ampliar desigualdades no acesso à tecnologia entre países desenvolvidos e em desenvolvimento.

Um aspecto crítico que limita a adoção clínica das tecnologias de inteligência artificial no rastreamento e diagnóstico do câncer de mama é a ausência de estudos multicêntricos e de longo prazo. Embora a maioria das pesquisas apresente métricas técnicas promissoras, como alta acurácia, sensibilidade e especificidade, ainda é incerta a capacidade desses algoritmos de manter desempenho consistente em populações diversas e ao longo do tempo. Essa limitação gera insegurança quanto à generalização dos resultados, uma vez que fatores como etnia, densidade mamária, protocolos de imagem e variabilidade entre centros podem influenciar significativamente os desfechos. Além disso, a falta de

acompanhamento prolongado impede a comprovação de benefícios concretos em desfechos clínicos reais, como redução de mortalidade, diminuição de procedimentos invasivos desnecessários e custo-efetividade em sistemas de saúde. Sem essas evidências robustas, profissionais, pacientes e órgãos reguladores tendem a adotar uma postura cautelosa, o que retarda a incorporação dessas tecnologias na prática clínica.

No campo regulatório, observa-se uma lacuna importante. Muitos estudos reportam métricas de desempenho (AUC, sensibilidade, especificidade), mas raramente abordam aspectos relacionados à responsabilidade ética e legal diante de erros diagnósticos. Essa ausência de regulamentações claras dificulta a incorporação em sistemas de saúde pública e privados. Além disso, a aceitação pelos pacientes também precisa ser considerada, visto que a confiança no diagnóstico mediado por algoritmos pode variar cultural e socialmente.

Em síntese, a literatura converge no reconhecimento da IA como ferramenta capaz de reduzir variabilidade interobservador e otimizar fluxos de trabalho (McKinney *et al.*, 2020; Dembrower *et al.*, 2020), mas diverge quanto à viabilidade de sua implementação imediata no rastreamento populacional. Há consenso de que estudos multicêntricos, longitudinais e em populações diversas são indispensáveis para validar a aplicabilidade clínica, avaliando não apenas métricas técnicas, mas também impactos econômicos, éticos e sociais de longo prazo.

CONSIDERAÇÕES FINAIS

Os estudos analisados demonstram que a inteligência artificial e o aprendizado de máquina estão revolucionando o diagnóstico, prognóstico e prevenção do câncer de mama. Os avanços incluem desde a interpretação automatizada de imagens mamográficas até a previsão da progressão tumoral, redução de procedimentos invasivos e melhoria na estratificação de risco.

No entanto, desafios como interpretabilidade dos modelos e validação clínica robusta ainda precisam ser superados para que essas tecnologias sejam amplamente adotadas na prática médica. Há uma necessidade de pesquisas que explorem a generalização dos modelos de

IA em populações diversas, considerando variações étnicas, geográficas e de densidade mamária. Além disso, a interpretabilidade dos modelos de IA continua sendo um desafio, exigindo o desenvolvimento de técnicas de IA explicável que possam ser facilmente compreendidas e adotadas por profissionais de saúde. Outra lacuna relevante é a falta de estudos que avaliem o impacto clínico de longo prazo da implementação de sistemas de

IA incluindo sua eficácia na redução de mortalidade e na melhoria da qualidade de vida das pacientes. Por fim, a integração de dados multimodais, como imagens mamográficas, dados genômicos e clínicos, em modelos de aprendizado de máquina representa uma área promissora para pesquisas futuras, com potencial para aprimorar ainda mais a precisão diagnóstica e prognóstica no câncer de mama.

REFERÊNCIAS

- ALBADR, M. A. A.; AYOB, M.; TIUN, S.; AL-DHIEF, F. T.; ARRAM, A.; KHALAF, S. Breast cancer diagnosis using the fast learning network algorithm. **Frontiers in Oncology**, v. 13, 2023. DOI: <https://doi.org/10.3389/fonc.2023.1150840>.
- ALHUSSAN, A. A.; ABDELHAMID, A. A.; TOWFEK, S. K.; IBRAHIM, A.; ABUALIGAH, L.; KHODADADI, N.; KHAFAGA, D. S.; AL-OTAIBI, S.; AHMED, A. E. Classification of Breast Cancer Using Transfer Learning and Advanced Al-Biruni Earth Radius Optimization. **Biomimetics**, v. 8, n.3, p.270, 2023. DOI: <https://doi.org/10.3390/biomimetics8030270>.
- ANDERSON, A. W.; MARINOVICH, M. L.; HOUSSAMI, N.; LOWRY, K. P.; ELMORE, J. G.; BUIST, D. S. M.; HOFVIND, S.; LEE, C. I. 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. DOI: <https://doi.org/10.1016/j.jacr.2021.11.008>.
- CHEN, J.-L.; CHENG, L.-H.; WANG, J.; HSU, T.-W.; CHEN, C.-Y.; TSENG, L.-M.; GUO, S.-M. A YOLO-based AI system for classifying calcifications on spot magnification mammograms. **BioMedical Engineering OnLine**, v. 22, n. 1, p. 54, 2023. DOI: <https://doi.org/10.1186/s12938-023-01115-w>.
- 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. DOI: <https://doi.org/10.59681/2175-4411.v16.iEspecial.2024.1289>.
- DEMBROWER, K.; WÄHLIN, E.; LIU, Y.; SALIM, M.; SMITH, K.; LINDHOLM, P.; EKLUND, M.; STRAND, F. 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. DOI: [https://doi.org/10.1016/S2589-7500\(20\)30185-0](https://doi.org/10.1016/S2589-7500(20)30185-0).
- DIETZE, M. M. A.; KUNNEN, B.; BRONTSEMA, F.; RAMAEKERS, P.; BEIJST, C.; AFIFAH, M.; BRAAT, A. J. A. T.; LAM, M. G. E. H.; DE JONG, H. W. A. M. 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. DOI: <https://doi.org/10.1007/s00330-021-08023-4>.
- DUGGENTO, A.; AIELLO, M.; CAVALIERE, C.; CASCELLA, G. L.; CASCELLA, D.; CONTE, G.; GUERRISI, M.; TOSCHI, N. 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. DOI: <https://doi.org/10.1155/2019/5982834>.
- FREEMAN, K.; GEPPERT, J.; STINTON, C.; TODKILL, D.; JOHNSON, S.; CLARKE, A.; TAYLOR-PHILLIPS, S. Use of artificial intelligence for image analysis in breast cancer screening programmes: systematic review of test accuracy. **BMJ**, p. n1872, 2021. DOI: <https://doi.org/10.1136/bmj.n1872>.

GONZÁLEZ-PATIÑO, D; VILLUENDAS-REY Y; SALDAÑA-PÉREZ M; ARGÜELLES-CRUZ AJ. 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. DOI: <https://doi.org/10.3390/ijerph20043240>.

HAJI MAGHSOUDI, O.; GASTOUNIOTI, A.; SCOTT, C.; PANTALONE, L.; WU, F.-F.; COHEN, E. A.; WINHAM, S.; CONANT, E. F.; VACHON, C.; KONTOS, D. 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. DOI: <https://doi.org/10.1016/j.media.2021.102138>.

HICKMAN, S. E.; WOITEK, R.; LE, E. P. V.; IM, Y. R.; MOURITSEN LUXHØJ, C.; AVILES-RIVERO, A. I.; BAXTER, G. C.; MACKAY, J. W.; GILBERT, F. J. Machine Learning for Workflow Applications in Screening Mammography: Systematic Review and Meta-Analysis. **Radiology**, v. 302, p. 88–104, 2022. DOI: <https://doi.org/10.1148/radiol.2021210391>.

HOUSSAMI, N.; KIRKPATRICK-JONES, G.; NOGUCHI, N.; LEE, C. I. 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. DOI: <https://doi.org/10.1080/17434440.2019.1610387>.

HUSSAIN, S.; ALI, M.; NASEEM, U.; NEZHADMOGHADAM, F.; JATOI, M. A.; GULLIVER, T. A.; TAMEZ-PEÑA, J. G. Breast cancer risk prediction using machine learning: a systematic review. **Frontiers in Oncology**, v. 14, 20 mar. 2024. DOI: <https://doi.org/10.3389/fonc.2024.1343627>.

LAMY, J.-B.; SEKAR, B.; GUEZENNEC, G.; BOUAUD, J.; SÉROUSSI, B. Explainable artificial intelligence for breast cancer: A visual case-based reasoning approach. **Artificial Intelligence in Medicine**, v. 94, p. 42–53, 2019. DOI: <https://doi.org/10.1016/j.artmed.2019.01.001>.

LI, H.; ROBINSON, K.; LAN, L.; BAUGHAN, N.; CHAN, C.-W.; EMBURY, M.; WHITMAN, G. J.; EL-ZEIN, R.; BEDROSIAN, I.; GIGER, M. L. Temporal Machine Learning Analysis of Prior Mammograms for Breast Cancer Risk Prediction. **Cancers**, v. 15, n. 7, p. 2141, 2023. DOI: <https://doi.org/10.3390/cancers15072141>.

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. DOI: <https://doi.org/10.1038/s41586-019-1799-6>.

MENG, M.; LI, H.; ZHANG, M.; HE, G.; WANG, L.; SHEN, D. 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. DOI: <https://doi.org/10.1186/s12880-023-01023-4>.

MONTAZERI, M.; MONTAZERI, M.; MONTAZERI, M.; BEIGZADEH, A. Machine learning models in breast cancer survival prediction. **Technology and Health Care**, v. 24, n. 1, p. 31–42, 2016. DOI: <https://doi.org/10.3233/THC-151071>.

MOTA, AM.; CLARKSON, M.J.; ALMEIDA, P.; MATELA, N. Automatic Classification of Simulated Breast Tomosynthesis Whole Images for the Presence of Microcalcification Clusters Using Deep CNNs. **Journal of Imaging**, v. 8, n. 9, p. 231, 29 ago. 2022. DOI: <https://doi.org/10.3390/jimaging8090231>.

MOURA FILHO, J. O. F.; DA SILVA, M. E.; GOMES, K. A. S.; DE SOUZA, S. D.; AMORA, M. A. B. Detecção de câncer de mama por imagem com classificador híbrido. **Journal of Health Informatics**, v. 16, n. Especial, 19 nov. 2024. DOI: <https://doi.org/10.59681/2175-4411.v16.iEspecial.2024.1353>.

RADAK, M.; LAFTA, H. Y.; FALLAHI, H. Machine learning and deep learning techniques for breast cancer diagnosis and classification: a comprehensive review of medical imaging studies. **Journal of Cancer Research and Clinical Oncology**, v. 149, n. 12, p. 10473–10491, 6 set. 2023. DOI: <https://doi.org/10.1007/s00432-023-06670-1>.

04956-z.

SUNG, H.; FERLAY, J.; SIEGEL, R. L.; LAVERSANNE, M.; SOERJOMATARAM, I.; JEMAL, A.; BRAY, F. 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. DOI: <https://doi.org/10.3322/caac.21660>.

WATANABE, A. T.; LIM, V.; VU, H. X.; CHIM, R.; WEISE, E.; LIU, J.; BRADLEY, W. G.; COMSTOCK, C. E. 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. DOI: <https://doi.org/10.1007/s10278-019-00192-5>.