Journal of Health Informatics

J Health Inform. 2026;18:e1803
DOI: https://doi.org/10.59681/2175-4411.v18.iEspecial.2026.1803

ARTIGO COMPLETO
CBIS 2026

Classificação de imagens para detecção de câncer de mama utilizando redes neurais convolucionais autorais e pré-treinadas

Image classification for breast cancer detection using custom and pretrained convolutional neural networks

Laryssa Rayane Zortea[1], Kathya Silvia Collazos Linares[1], Luiz Fernando Puttow Southier[1], Marco Antonio de Castro Barbosa[1], Kelly Lais Wiggers[2], Jefferson Tales Oliva[1] ✉

ORCID: 0009-0007-6684-5697 · 0000-0003-3503-0915 · 0000-0003-2420-4094 · 0000-0001-9674-2348 · 0000-0002-2643-5331 · 0000-0003-1574-1293

[1] Universidade Tecnológica Federal do Paraná, Pato Branco (PR), Brasil. [2] Universidade Estadual do Centro-Oeste, Guarapuava (PR), Brasil.

FICHA DO ARTIGO

TIPO
Artigo completo · CBIS 2026

IDENTIFICADOR
e1803

DOI
10.59681/2175-4411.v18.iEspecial.2026.1803

RECEBIDO
17/05/2026

APROVADO
20/07/2026

PROCESSO DE AVALIAÇÃO
Double Blind Review

EDITOR RESPONSÁVEL
Juliano de Souza Gaspar

ACESSO
Aberto, CC BY 4.0

AUTOR CORRESPONDENTE
Jefferson Tales Oliva
jeffersonoliva@utfpr.edu.br

LICENÇA

Este é um artigo publicado em acesso aberto sob a licença Creative Commons CC BY 4.0, que permite uso, distribuição e reprodução em qualquer meio, desde que o trabalho original seja corretamente citado.

CC BY 4.0

RESUMO

Objetivo: Desenvolver e avaliar modelos computacionais para a classificação de tumores mamários, investigando o impacto de diferentes técnicas de processamento de imagens no desempenho das arquiteturas. **Métodos:** Foram utilizadas imagens do dataset CBIS-DDSM, submetidas a técnicas de processamento, como Equalização de Histograma Adaptativa com Limitação de Contraste (CLAHE, Contrast Limited Adaptive Histogram Equalization) e Transformada Discreta de Fourier. Os dados foram aplicados a uma Rede Neural Convolucional (CNN, Convolutional Neural Network) autoral e às arquiteturas pré-treinadas VGG16 e ResNet50, avaliadas por meio de acurácia, AUC, precisão e revocação. **Resultados:** A VGG16 apresentou o melhor desempenho, com AUC de 0,701. As arquiteturas pré-treinadas mostraram baixa sensibilidade ao processamento de imagens, enquanto a CNN autoral apresentou maior evolução e melhor resposta às transformações aplicadas. **Conclusão:** Modelos pré-treinados apresentam bom desempenho inicial, enquanto arquiteturas autorais demonstram maior potencial de adaptação e aprimoramento com menor custo computacional.

Descritores: Neoplasias da Mama; Mamografia; Redes Neurais de Computação.

ABSTRACT

Objective: To develop and evaluate computational models for the classification of breast tumors, investigating the impact of different image processing techniques on the performance of the architectures. **Methods:** Images from the CBIS-DDSM dataset were processed using Contrast Limited Adaptive Histogram Equalization (CLAHE) and the Discrete Fourier Transform. The data were applied to a custom Convolutional Neural Network (CNN) and to the pre-trained architectures VGG16 and ResNet50, evaluated by accuracy, AUC, precision, and recall. **Results:** VGG16 showed the best performance, with an AUC of 0.701. The pre-trained architectures showed low sensitivity to image processing, while the custom CNN showed greater evolution and a better response to the applied transformations. **Conclusion:** Pre-trained models achieve good initial performance, while custom architectures demonstrate greater potential for adaptation and improvement with lower computational cost.

Keywords: Breast Neoplasms; Mammography; Neural Networks, Computer.

CBIS 2026 XXI CONGRESSO BRASILEIRO DE INFORMÁTICA EM SAÚDE

Artigo apresentado no XXI Congresso Brasileiro de Informática em Saúde (CBIS 2026), realizado de 23 a 25 de setembro de 2026, em Brasília (DF), e publicado na seção CBIS 2026 do Journal of Health Informatics.

COMO CITAR ESTE ARTIGO: Zortea LR, Collazos Linares KS, Southier LFP, Barbosa MAC, Wiggers KL, Oliva JT. Classificação de imagens para detecção de câncer de mama utilizando redes neurais convolucionais autorais e pré-treinadas. J Health Inform 2026;18:e1803. doi: https://doi.org/10.59681/2175-4411.v18.iEspecial.2026.1803

1 INTRODUÇÃO

O câncer de mama feminina é o segundo mais comum entre as mulheres brasileiras, superado apenas pelo câncer de pele não melanoma. Em termos de mortalidade, entretanto, constitui a principal causa de óbito por câncer nessa população. O Instituto Nacional de Câncer (INCA) estima que, em cada ano do triênio de 2026 a 2028, sejam diagnosticados 78.610 novos casos, o que corresponde a um risco de 71,57 casos por 100 mil mulheres [1].

O declínio das taxas de mortalidade por câncer de mama em países desenvolvidos é resultado direto dos avanços na pesquisa e no tratamento, o que leva a uma detecção precoce. A identificação nas fases iniciais mostra-se crucial para um tratamento bem-sucedido, podendo reduzir a taxa de mortalidade de 40% para 15% [2,3]. No cenário nacional, o Sistema Único de Saúde (SUS) orienta o rastreamento do câncer de mama por meio da mamografia bienal para mulheres entre 50 e 74 anos, assintomáticas. Em 2024, foram realizadas 4.405.597 mamografias em mulheres através do SUS, das quais 385.428 foram destinadas à investigação de casos sintomáticos e 4.020.169 ao rastreamento [4].

A imagem gerada por um exame de mamografia é a principal ferramenta para o diagnóstico do câncer de mama, capaz de detectar alterações nos tecidos mamários até um ou dois anos antes do aparecimento de sintomas clínicos [5]. A análise dos mamogramas envolve a detecção de tumores e a avaliação de sua gravidade. Em casos de suspeita de malignidade, exames adicionais, como biópsias e testes sanguíneos, são recomendados, o que atrasa o diagnóstico e gera estresse significativo às pacientes [6].

Somado a isso, o crescente volume de imagens médicas geradas por exames torna a análise mais complexa. Esse desafio se intensifica com o aumento no número de exames, a fragmentação das áreas médicas em subespecialidades, que exige uma formação mais específica, e o avanço das técnicas de imagem, que ampliam o volume de detalhes disponíveis. Como consequência, torna-se mais difícil para médicos especialistas adquirir conhecimento aprofundado na análise de diferentes regiões anatômicas [7].

As técnicas de aprendizado profundo têm ocupado um papel central no avanço da computação médica, com destaque para as redes neurais convolucionais (CNNs), amplamente empregadas em tarefas de análise de imagens. Essas arquiteturas se destacam pela capacidade de extrair automaticamente padrões relevantes, como forma, textura e contornos de lesões. Do ponto de vista estrutural, são compostas principalmente por camadas convolucionais, responsáveis pela extração de características por meio do compartilhamento de pesos, e por camadas de *pooling*, que realizam a redução da dimensionalidade, contribuindo para a eficiência do modelo [8].

A eficácia das CNNs em tarefas de detecção e classificação de imagens, aliada à sua capacidade de operar sobre grandes volumes de dados e aprender representações complexas, fez com que essa abordagem se tornasse dominante na área. No entanto, no contexto de imagens médicas, a disponibilidade limitada de bases anotadas impõe desafios adicionais ao treinamento desses modelos. Como alternativa, é comum o uso de técnicas de transferência de aprendizado, nas quais modelos treinados em bases extensas de imagens naturais, como o ImageNet, são adaptados para tarefas específicas. Essa estratégia permite aproveitar o conhecimento já adquirido, com o ajuste das camadas finais da rede para a identificação de características relevantes da tarefa médica em questão, como observado no uso de arquiteturas como VGG16 e ResNet50 [8-10]. Embora essa estratégia permita aproveitar conhecimento prévio, as diferenças entre imagens naturais e médicas podem comprometer a generalização e favorecer o *overfitting*. Além disso, evidências indicam que o aprendizado por transferência é mais eficaz quando realizado dentro do próprio domínio, utilizando dados semelhantes ao problema em questão [11].

Diante desse cenário, este trabalho teve como objetivo o desenvolvimento de modelos computacionais que combinam diferentes técnicas de pré-processamento e classificação, aplicados em imagens de tumores mamários. Para isso, foram investigadas arquiteturas de diferentes níveis de complexidade, incluindo uma CNN autoral e arquiteturas pré-treinadas. Como resultado, foi possível comparar os modelos quanto ao desempenho e ao custo computacional, identificando a abordagem que melhor concilie esses fatores, com maior viabilidade de aplicação e maior potencial de evolução.

2 REVISÃO DE LITERATURA

Esta revisão de literatura concentra-se em estudos de classificação binária do câncer de mama, com identificação de tumores como benignos ou malignos, priorizando artigos publicados que utilizam a mesma base de dados, apresentada na seção de métodos.

Sajid *et al.* [3] desenvolveram um *framework* que integra características aprendidas por uma CNN com características selecionadas manualmente, empregando uma nova arquitetura denominada cVGG. O vetor unificado de características extraídas pela cVGG foi utilizado como entrada para três algoritmos de classificação: Random Forest, KNN (*k-nearest neighbors*) e XGBoost; este último atingiu maior acurácia, sendo de 91,5%.

Bouzar-Benlabiod *et al.* [6] propuseram uma abordagem que utiliza um sistema de Raciocínio Baseado em Casos (CBR, *Case-Based Reasoning*), cuja precisão depende da qualidade das características extraídas. Integrando

Aprendizado Profundo (AP) ao CBR para aumentar a precisão da classificação, o sistema é capaz de diferenciar descritores com maior valor preditivo, atribuindo pesos diferentes conforme sua relevância diagnóstica. A abordagem alcançou uma acurácia de 86,71% e sensibilidade de 91,34%.

Gerbasi *et al.* [12] voltam-se à detecção de microcalcificações, que podem representar os primeiros sinais radiográficos de câncer e constituem um desafio para a análise manual. A arquitetura autoral DeepMica combina técnicas de pré-processamento das imagens com modelos especializados para segmentação e classificação, alcançando respectivamente resultados de 0,95 e 0,89 utilizando a métrica Área Sob a Curva (AUC, *Area Under the Curve*).

Raiaan *et al.* [13] desenvolveram a arquitetura Mammo-Light, que prioriza a eficiência computacional por meio de uma CNN compacta com 10 camadas. A abordagem dispensa a segmentação das regiões tumorais e concentra-se em um pré-processamento mais robusto para aprimorar a qualidade das imagens. Nos experimentos conduzidos na base de dados CBIS-DDSM, o modelo alcançou 99,17% de acurácia.

Kulandaivelu *et al.* [14] propõem uma abordagem que incorpora fundamentos matemáticos em todo o *pipeline*, combinando técnicas de filtragem, segmentação e extração de características para realçar padrões relevantes nas imagens antes da etapa de classificação. O modelo autoral desenvolvido integra informações em diferentes níveis de abstração, alcançando acurácia superior a 98%.

Li *et al.* [15] introduzem um método de classificação de massas baseado na arquitetura DenseNet121, utilizando transferência de aprendizado e adaptação da camada final para a tarefa binária. O modelo utiliza máscaras binárias para gerar mapas de ativação de referência, que são usados durante o treinamento para guiar os mapas de ativação da CNN, forçando o modelo a focar nas regiões correspondentes à lesão. Também inclui um módulo de interpretabilidade que relaciona regiões relevantes a características clínicas, como a distinção entre lesão e tecido de fundo. O modelo alcançou acurácia de 86,1 ± 3,4%.

Até o momento, não há um consenso sobre qual estratégia melhor equilibra custo computacional e desempenho na classificação de imagens mamográficas. Ainda são pouco frequentes os estudos que exploram caminhos intermediários entre abordagens voltadas exclusivamente à maximização do desempenho, independentemente do custo computacional, e aquelas que priorizam a redução desse custo por meio da simplificação de etapas relevantes do processamento. Considerando a escassez de comparativos diretos, o presente trabalho investiga ambas as filosofias com o objetivo de compreender melhor seus padrões de comportamento e limitações, propondo um caminho intermediário que preserve a viabilidade de aplicação em cenários clínicos reais.

3 MÉTODOS

3.1 Base de Dados

A base de dados utilizada neste trabalho foi a CBIS-DDSM (https://doi.org/10.7937/K9/TCIA.2016.7O02S9CY), amplamente empregada em estudos do estado da arte em classificação de tumores em mamogramas, devido às imagens de alta resolução e às máscaras de Regiões de Interesse (ROIs, *Regions of Interest*) validadas por patologistas. Ao todo, a base é composta por 886 casos benignos e 758 malignos, organizados em diretórios específicos por paciente, podendo cada paciente apresentar mais de um tumor visível na região mamária. Além disso, a base fornece informações sobre a natureza dos tumores, classificando-os como massas ou calcificações [16-18].

3.2 Pré-processamento e segmentação

O isolamento de ROIs tumorais torna possível a extração de características discriminativas, como formato, textura e dimensões [19,20]. A partir das máscaras disponíveis na base de dados, realizou-se a segmentação das lesões por meio de recorte, resultando em imagens contendo exclusivamente o tumor a ser analisado. Nos casos em que um mamograma contém múltiplas lesões, os tumores foram isolados e processados individualmente. Essa abordagem gerou um volume de imagens superior ao original, levando à reorganização da base por unidade tumoral.

Para lidar com as diferenças sutis de brilho entre os tecidos mamários, que podem levar a equívocos de classificação, foi aplicada uma etapa de realce utilizando o método de CLAHE [6,12]. Essa técnica atua processando pequenas regiões da imagem de forma independente, promovendo melhor distribuição dos níveis de cinza e realçando os detalhes locais sem amplificar excessivamente o ruído. Para os experimentos, os parâmetros configurados para o CLAHE foram limiar de contraste igual a 5 e tamanho da janela igual a 4.

Ainda que a etapa de realce tenha destacado nuances entre os tecidos, as lesões tumorais do conjunto de dados ainda apresentam similaridades morfológicas significativas. Para contornar essas limitações, o método no domínio de frequência, denominado Transformada Discreta de Fourier (DFT, *Discrete Fourier Transform*), foi aplicado. Sua aplicação em imagens permite decompor o conteúdo visual em diferentes componentes, destacando padrões estruturais e variações de estrutura que nem sempre são perceptíveis no domínio espacial [19].

Tabela 1. Especificações detalhadas das camadas da CNN sequencial.

Camada (Tipo)	Especificações	Camada (Tipo)	Especificações
Entrada	256 x 256 x 1	MaxPooling2D	Pool: 2x2
Conv2D	16 filtros (3x3), ReLU	Flatten	—
MaxPooling2D	Pool: 2x2	Densa	32 unidades, ReLU
Dropout	0,25	Dropout	0,5
Conv2D	32 filtros (3x3), ReLU	Saída	1 unidade, Sigmoid
Conv2D	16 filtros (3x3), ReLU	—	—

Fonte: Elaborado pelos autores (2026).

3.3 Construção dos modelos preditivos

Neste trabalho, foram utilizadas uma arquitetura CNN autoral e duas arquiteturas pré-treinadas, sendo os experimentos iniciais conduzidos na arquitetura autoral sequencial composta por 10 camadas, conforme detalhada na Tabela 1. Sua implementação foi focada na redução do custo computacional e, consequentemente, na redução da complexidade da rede, o que poderia viabilizar o uso do modelo em sistemas com recursos limitados.

O uso de *dropout* foi adotado como estratégia para reduzir o *overfitting*, considerando o tamanho reduzido do conjunto de dados em relação à complexidade visual das imagens, fatores que podem favorecer a memorização de ruídos. Adicionalmente, foi empregada uma estratégia de otimização de hiperparâmetros baseada em *Random Search*, visando a seleção de combinações mais adequadas durante o processo de treinamento.

O modelo convolucional inicial estabeleceu uma linha de base, servindo como referência para a comparação de desempenho com modelos pré-treinados e abordagens mais sofisticadas. A seleção das arquiteturas foi guiada pela revisão de literatura, em que VGG e ResNet são empregadas nos trabalhos de Gerbasi *et al.* [12], Sajid *et al.* [3] e Bouzar-Benlabiod *et al.* [6]. Assim, foram escolhidas as arquiteturas VGG16 e ResNet50, representando diferentes níveis de profundidade.

A arquitetura VGG16 [21] destaca-se pela sua simplicidade e estrutura simétrica, sendo composta por 16 camadas, das quais 13 são convolucionais. Pré-treinada no conjunto de dados ImageNet, a arquitetura foi redirecionada para o reconhecimento de características tumorais por meio de ajustes na rede. As camadas convolucionais foram mantidas congeladas, preservando o conhecimento previamente adquirido, enquanto as últimas quatro camadas foram descongeladas para retreinamento com as imagens dos tumores, permitindo a adaptação do modelo para padrões não representados no ImageNet. Novas camadas densas foram adicionadas ao topo da rede para adequar a saída ao problema de classificação binária.

A arquitetura ResNet50 [22] foi implementada de forma semelhante, mantendo a base convolucional inicial congelada e liberando as quatro últimas unidades residuais para adaptação ao problema. Diferentemente da VGG16, que possui uma estrutura sequencial, a ResNet50 utiliza conexões residuais que facilitam o treinamento de redes profundas e a captura de relações mais complexas entre as características.

Para garantir um treinamento eficiente, foram aplicadas estratégias de *callback* para monitorar o desempenho do modelo a cada época e ajustar seu comportamento conforme os resultados obtidos. Essas rotinas otimizam o processo de aprendizado e evitam problemas como *overfitting* e desperdício de recursos computacionais. As principais técnicas empregadas foram:

- **EarlyStopping:** interrompe o treinamento quando não há melhora na validação.
- **ModelCheckpoint:** salva o modelo com melhor desempenho.
- **ReduceLROnPlateau:** ajusta a taxa de aprendizado quando o desempenho estagna.

3.4 Métricas de avaliação

O desempenho dos modelos foi avaliado por métricas amplamente utilizadas em visão computacional, como acurácia, precisão, revocação e AUC, sendo a acurácia a mais recorrente na literatura.

- **Acurácia:** mensura a proporção de predições corretas em relação ao total de amostras avaliadas.
- **Precisão:** determina a proporção de predições positivas que realmente pertencem à classe positiva.
- **Revocação:** estabelece a proporção de casos positivos que o modelo foi capaz de identificar corretamente.
- **AUC:** mensura a capacidade do modelo de distinguir entre classes ao longo de diferentes limiares, sendo calculada como a área sob a curva ROC, que relaciona a taxa de verdadeiros positivos e a taxa de falsos positivos.

Neste trabalho, adotou-se o AUC como métrica principal, por oferecer uma medida mais informativa da capacidade discriminativa dos modelos. Como referência de desempenho, estudos indicam que radiologistas humanos atingem, em média, acurácia de 0,83 e AUC de 0,77 em tarefas de triagem mamográfica [23], estabelecendo uma referência de desempenho a ser alcançada. Adicionalmente, optou-se também por enfatizar a revocação, devido ao seu papel crítico na detecção de casos malignos cuja falha pode comprometer decisões clínicas.

4 RESULTADOS E DISCUSSÃO

As imagens utilizadas como entrada nos experimentos são ilustradas na Figura 1, na qual são apresentadas as transformações aplicadas a um mamograma exemplo. A segmentação da região tumoral permitiu isolar a área de interesse, reduzindo a influência de estruturas externas, como tecidos mamários e ruídos, na análise. O realce dos tecidos feito com a técnica de CLAHE evidenciou padrões como textura e contraste em relação aos tecidos de fundo, enquanto a representação no domínio da frequência, obtida pela DFT, complementou essa análise ao destacar características estruturais menos perceptíveis no domínio espacial.

Os resultados do presente estudo são apresentados na Tabela 2.

Embora não tenha alcançado os melhores resultados absolutos, a CNN autoral apresentou a maior evolução relativa. Saindo de um cenário inicial de *overfitting* severo, a capacidade de generalização do modelo evoluiu de forma consistente ao longo das etapas de processamento das imagens, com progresso estável e coerente entre as métricas ao longo do treinamento. Mesmo com a aplicação de um número limitado de técnicas de pré-processamento, foi possível obter uma melhora de 0,151 nos valores de AUC.

A aplicação da DFT no pré-processamento trouxe resultados positivos para a CNN proposta, conforme ilustrado na Figura 2. As curvas de treinamento indicam uma tendência de convergência, com evolução progressiva das métricas analisadas, acompanhada de uma redução da função de perda. Embora o treinamento tenha sido interrompido por limitações de hardware, os resultados indicam que o modelo poderia alcançar um desempenho superior com a ampliação do número de épocas. Esse comportamento indica potencial de aprimoramento, sugerindo que ajustes adicionais e maior tempo de treinamento poderiam melhorar o desempenho da rede.

A partir dos resultados apresentados na Tabela 2, é possível observar também que os modelos pré-treinados pouco se beneficiaram das etapas de pré-processamento. O desempenho dessas arquiteturas foi fortemente influenciado pelo conhecimento adquirido previamente mais do que pelas transformações realizadas sobre as imagens do conjunto de dados.

A VGG16 apresentou o melhor desempenho geral. No conjunto de validação, o modelo atingiu um AUC de 0,791, superando o desempenho médio dos radiologistas relatado por Wang [23]. Esse comportamento se manteve no conjunto de testes, com AUC de 0,701 e 0,707, além de revocação de 0,942, demonstrando alta sensibilidade na detecção de casos positivos

Figura 1. a) Imagem original. b) Segmentação da região tumoral. c) Recorte da região tumoral com aplicação de realce por CLAHE. d) Representação da ROI no domínio da frequência por meio da DFT aplicada ao recorte com realce.

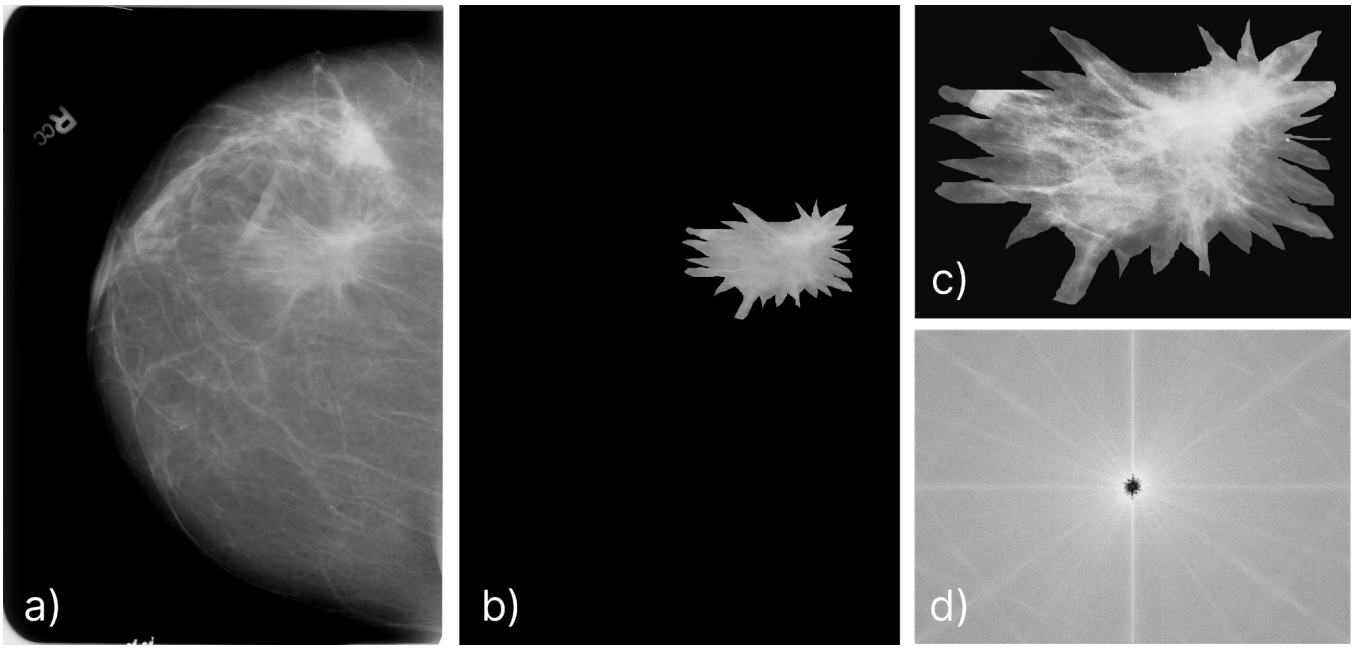

Fonte: Elaborado pelos autores (2026).

Tabela 2. Desempenho dos modelos avaliados nas diferentes configurações de pré-processamento.

Modelo	Pré-processamento	Épocas	Acurácia	AUC	Revocação	Precisão
CNN	—	10	0,398	0,500	1,000	0,398
CNN	CLAHE	10	0,537	0,633	0,750	0,451
CNN	CLAHE + Fourier	10	0,621	0,637	0,449	0,528
CNN	CLAHE + Fourier	30	0,626	0,651	0,493	0,533
VGG16	—	10	0,535	0,684	0,891	0,457
VGG16	CLAHE	10	0,563	0,707	0,815	0,472
VGG16	CLAHE	30	0,512	0,701	0,942	0,447
VGG16	CLAHE + Fourier	30	0,520	0,661	0,902	0,449
ResNet50	—	10	0,547	0,671	0,844	0,462
ResNet50	CLAHE	10	0,618	0,662	0,500	0,521
ResNet50	CLAHE	30	0,520	0,667	0,920	0,450
ResNet50	CLAHE + Fourier	30	0,527	0,635	0,870	0,451

Fonte: Elaborado pelos autores (2026).

Figura 2. Curvas de treinamento e validação da CNN autoral ao longo das épocas, com pré-processamento baseado em DFT.

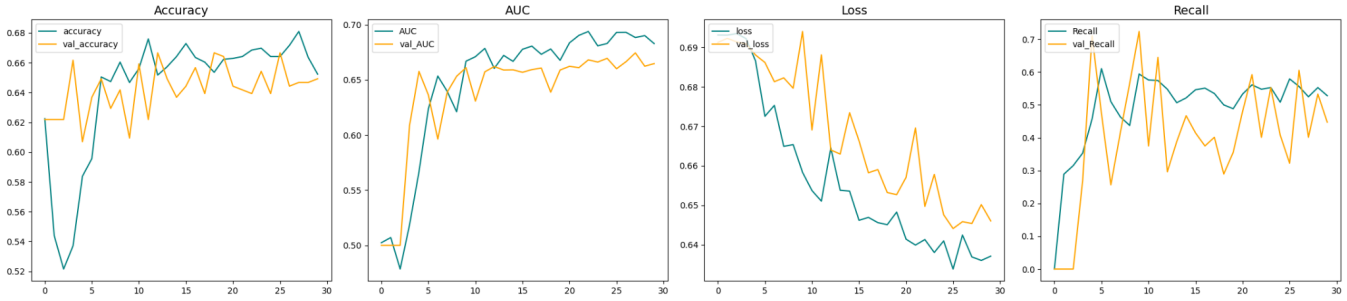

Fonte: Elaborado pelos autores (2026).

para malignidade. No entanto, a estabilidade observada nos valores obtidos indica que esses resultados estão mais associados à robustez da arquitetura do que às etapas de pré-processamento empregadas.

Por outro lado, a ResNet50 apresentou os piores resultados dentre os modelos, possivelmente devido à sua maior profundidade, que pode ter prejudicado a capacidade de generalização. Esse comportamento também foi observado por Gerbasi *et al.* [12], que recomendam o uso de arquiteturas menos profundas, citando como exemplo a ResNet18 e a VGG16. Adicionalmente, a ResNet50 mostrou indícios de *overfitting*, com métricas de validação consistentemente superiores às obtidas no conjunto de testes.

Observa-se que a ResNet50 obteve o melhor valor de AUC no conjunto de testes ao utilizar a versão menos refinada dos dados, composta apenas pela região tumoral segmentada na imagem original. Esse comportamento pode estar relacionado ao fato de que, nesse cenário, as informações de escala e contexto espacial foram preservadas, sugerindo que essas informações favorecem o desempenho da arquitetura.

De forma geral, os resultados indicam que arquiteturas pré-treinadas apresentam bom desempenho com menor necessidade de transformações nas imagens da base de dados, alcançando rapidamente resultados comparáveis aos de especialistas. No entanto, é aconselhável que a otimização desses modelos realize ajustes no processo de treinamento e na configuração de suas camadas internas, uma vez que o impacto do processamento das imagens é limitado diante do conhecimento previamente adquirido em grandes volumes de dados.

Em contrapartida, arquiteturas desenvolvidas sem uso de pesos pré-treinados mostraram maior sensibilidade às transformações aplicadas às imagens, permitindo ganhos de desempenho com menor custo computacional. Além disso, a CNN autoral demonstrou maior potencial de adaptação e evolução, com aumento aproximado de 30% no AUC em relação à configuração inicial, enquanto as arquiteturas pré-treinadas apresentaram comportamento mais rígido.

A comparação da complexidade das arquiteturas revelou que a CNN autoral possui 1.914.641 parâmetros treináveis, enquanto a VGG16 e a ResNet50 apresentam, respectivamente, 14.780.481 e 23.850.113 parâmetros. Essa diferença evidencia a menor complexidade da arquitetura proposta e sugere menor demanda por memória e recursos computacionais.

Ao combinar uma arquitetura de baixa complexidade com técnicas robustas de pré-processamento previamente aplicadas, torna-se possível melhorar o desempenho sem recorrer a arquiteturas profundas, sustentando a estratégia intermediária adotada neste trabalho. A elevada responsividade da CNN autoral às transformações aplicadas indica que a exploração de novas técnicas ou combinações de pré-processamento representa uma direção promissora para trabalhos futuros, uma vez que a baixa complexidade da arquitetura favorece esse tipo de investigação sem aumentar significativamente a demanda computacional.

5 CONCLUSÕES

Este trabalho teve por objetivo o desenvolvimento de modelos computacionais que combinam diferentes técnicas de pré-processamento e classificação, aplicados em imagens de tumores mamários provenientes do *dataset* CBIS-DDSM. As imagens foram submetidas a transformações de processamento digital e utilizadas como entrada nas arquiteturas pré-treinadas VGG16 e ResNet50 e em uma CNN autoral sequencial de 10 camadas.

O melhor desempenho foi obtido pela VGG16, com AUC de 0,701. Mesmo assim, o modelo autoral foi o que apresentou maior responsividade às técnicas aplicadas às imagens e maior capacidade de evolução ao longo dos experimentos, indicando potencial para aprimoramento em investigações futuras. Além disso, as melhorias nessa arquitetura podem ser obtidas com menor custo computacional e apresentam uma possibilidade para superar o desempenho das redes pré-treinadas.

Como contribuição, os resultados experimentais demonstram que CNNs sem pré-treinamento apresentam maior sensibilidade às técnicas de pré-processamento de imagens, enquanto arquiteturas pré-treinadas tendem a ser menos influenciadas por essas transformações, dependendo predominantemente do conhecimento adquirido em etapas prévias de treinamento. Além disso, observa-se que modelos mais leves, como CNNs autorais, configuram-se como alternativas viáveis, apresentando menor custo computacional, maior flexibilidade e maior potencial de evolução, além de maior consistência na resposta a alterações no *pipeline* de processamento.

Por se tratar de um campo ainda em amadurecimento, a classificação de tumores mamários oferece amplo espaço para exploração de novas abordagens. Os resultados obtidos evidenciam não apenas os desafios envolvidos, mas também as oportunidades de avanço, reforçando o papel da pesquisa na construção de soluções cada vez mais eficazes.

Como perspectiva para trabalhos futuros, destaca-se a exploração de abordagens que considerem separadamente diferentes tipos de lesões mamárias, como massas e calcificações, que apresentam características distintas de forma, textura e escala. Essa diferenciação pode favorecer a aprendizagem de representações mais adequadas, em contraste com abordagens que buscam generalizar padrões entre categorias heterogêneas.

Adicionalmente, a incorporação de atributos complementares relacionados ao tumor, como medidas de dimensão e área, pode enriquecer a representação das imagens, especialmente considerando que parte dessas informações é perdida durante o recorte e redimensionamento das regiões de interesse.

Essas abordagens sugerem caminhos que abrem espaço para avanços na forma como os modelos representam características importantes do ponto de vista clínico.

Contribuição dos autores. Os autores contribuíram igualmente em todas as etapas de construção do artigo: concepção e delineamento do estudo; coleta, análise e interpretação dos dados; redação e revisão crítica do manuscrito; e aprovação da versão final.

Agradecimentos. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, Brasil (CAPES), Código de Financiamento 001.

Financiamento. Os autores não declararam fonte de financiamento.

Disponibilidade de dados e materiais. Os autores não declararam a disponibilidade dos dados e materiais da pesquisa.

Conflitos de interesse. Os autores não declararam conflitos de interesse.

Declaração de uso de IA. A concepção intelectual, a definição dos temas e os argumentos deste manuscrito são de responsabilidade dos autores. O texto contou com o apoio de um modelo de linguagem baseado em Inteligência Artificial exclusivamente para fins de revisão estilística e gramatical, não interferindo na autoria, na originalidade do conteúdo nem na responsabilidade dos autores pelo material submetido.

REFERÊNCIAS

1. Instituto Nacional de Câncer (Brasil). Estimativa 2026: incidência de câncer no Brasil [Internet]. INCA; 2026 [citado 30 de março de 2026]. Disponível em: https://ninho.inca.gov.br/jspui/handle/123456789/17914

2. AlSamhori JF, AlSamhori ARF, Duncan LA, Qalajo A, Alshahwan HF, Al-abbadi M, et al. Artificial intelligence for breast cancer: Implications for diagnosis and management. Journal of Medicine, Surgery, and Public Health. 2024;3:100120. doi: https://doi.org/10.1016/j.glmedi.2024.100120

3. Sajid U, Khan RA, Shah SM, Arif S. Breast cancer classification using deep learned features boosted with handcrafted features. Biomedical Signal Processing and Control. 2023;86:105353. doi: https://doi.org/10.1016/j.bspc.2023.105353
4. Instituto Nacional de Câncer (Brasil). Controle do câncer de mama no Brasil : dados e números 2025 [Internet]. INCA; 2025 [citado 30 de março de 2026]. Disponível em: https://ninho.inca.gov.br/jspui/handle/123456789/17733
5. Houssein EH, Emam MM, Ali AA, Suganthan PN. Deep and machine learning techniques for medical imaging-based breast cancer: A comprehensive review. Expert Systems with Applications. 2021;167:114161. doi: https://doi.org/10.1016/j.eswa.2020.114161
6. Bouzar-Benlabiod L, Harrar K, Yamoun L, Khodja MY, Akhloufi MA. A novel breast cancer detection architecture based on a CNN-CBR system for mammogram classification. Comput Biol Med. 2023;163:107133. doi: https://doi.org/10.1016/j.compbiomed.2023.107133
7. Yeasmin MN, Al Amin M, Joti TJ, Aung Z, Azim MA. Advances of AI in image-based computer-aided diagnosis: A review. Array. 2024;23:100357. doi: https://doi.org/10.1016/j.array.2024.100357
8. Salama WM, Aly MH. Deep learning in mammography images segmentation and classification: Automated CNN approach. Alexandria Engineering Journal. 2021;60(5):4701-9. doi: https://doi.org/10.1016/j.aej.2021.03.048
9. Mendel K, Li H, Sheth D, Giger M. Transfer Learning From Convolutional Neural Networks for Computer-Aided Diagnosis: A Comparison of Digital Breast Tomosynthesis and Full-Field Digital Mammography. Acad Radiol. 2019;26(6):735-43. doi: https://doi.org/10.1016/j.acra.2018.06.019
10. Sorin V, Sklair-Levy M, Glicksberg BS, Konen E, Nadkarni GN, Klang E. Deep Learning for Contrast Enhanced Mammography - A Systematic Review. Acad Radiol. 2025;32(5):2497-508. doi: https://doi.org/10.1016/j.acra.2024.11.035
11. Atasever S, Azginoglu N, Terzi DS, Terzi R. A comprehensive survey of deep learning research on medical image analysis with focus on transfer learning. Clin Imaging. 2023;94:18-41. doi: https://doi.org/10.1016/j.clinimag.2022.11.003
12. Gerbasi A, Clementi G, Corsi F, Albasini S, Malovini A, Quaglini S, et al. DeepMiCa: Automatic segmentation and classification of breast MIcroCAlcifications from mammograms. Comput Methods Programs Biomed. 2023;235:107483. doi: https://doi.org/10.1016/j.cmpb.2023.107483
13. Raiaan MAK, Fahad NM, Mukta MSH, Shatabda S. Mammo-Light: A lightweight convolutional neural network for diagnosing breast cancer from mammography images. Biomedical Signal Processing and Control. 2024;94:106279. doi: https://doi.org/10.1016/j.bspc.2024.106279
14. Kulandaivelu G, Taluja A, Gawas M, Kumar Nath R. Automated breast cancer diagnosis optimized with higher-order attribute-enhancing heterogeneous graph neural networks using mammogram images. Biomedical Signal Processing and Control. 2024;97:106659. doi: https://doi.org/10.1016/j.bspc.2024.106659
15. Li G, Zhou M, Fu Y, Alam N, Denton E, Zwiggelaar R. An interpretable CNN-based model for mass classification in mammography. Knowledge-Based Systems. 2025;316:113372. doi: https://doi.org/10.1016/j.knosys.2025.113372
16. Lee RS, Gimenez F, Hoogi A, Miyake KK, Gorovoy M, Rubin DL. A curated mammography data set for use in computer-aided detection and diagnosis research. Sci Data. 2017;4:170177. doi: https://doi.org/10.1038/sdata.2017.177
17. Sawyer-Lee R, Gimenez F, Hoogi A, Rubin DL. Curated Breast Imaging Subset of Digital Database for Screening Mammography (CBIS-DDSM) [Internet]. [s.l.]: The Cancer Imaging Archive; 2016. doi: https://doi.org/10.7937/K9/TCIA.2016.7O02S9CY
18. Rahman A. CBIS-DDSM: Breast Cancer Image Dataset [Internet]. [citado 29 de outubro de 2024]. Disponível em: https://www.kaggle.com/datasets/awsaf49/cbis-ddsm-breast-cancer-image-dataset
19. Gonzalez RC, Woods RE. Processamento de imagens digitais. Editora Blucher; 2000.
20. Sahu A, Das PK, Meher S. Recent advancements in machine learning and deep learning-based breast cancer detection using mammograms. Phys Med. 2023;114:103138. doi: https://doi.org/10.1016/j.ejmp.2023.103138
21. Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition [Internet]. arXiv; 2015 [citado 20 de abril de 2026]. Disponível em: http://arxiv.org/abs/1409.1556 doi:10.48550/arXiv.1409.1556
22. He K, Zhang X, Ren S, Sun J. Deep Residual Learning for Image Recognition. In: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). [s.l.]: IEEE; 2016. p. 770-8. doi: https://doi.org/10.1109/cvpr.2016.90
23. Wang L. Mammography with deep learning for breast cancer detection. Front Oncol. 2024;14:1281922. doi: https://doi.org/10.3389/fonc.2024.1281922

NOTAS EDITORIAIS

O Journal of Health Informatics é uma publicação científica mantida pela Sociedade Brasileira de Informática em Saúde, associação científica sem fins lucrativos dedicada ao desenvolvimento da Informática em Saúde e da Saúde Digital no Brasil. O processo editorial é conduzido com independência científica, sem interferência institucional, comercial ou de patrocinadores, e segue as boas práticas internacionais de ética em publicação científica.

Este artigo foi avaliado por pares, em sistema duplo-cego, por especialistas da área. A equipe editorial usou ferramentas de inteligência artificial, com supervisão humana, na triagem inicial, na conferência do texto, das referências e dos números e, quando necessário, no redesenho de figuras, quadros e tabelas, aprovado pelos autores na prova. As ferramentas e as salvaguardas estão na Política de uso de inteligência artificial da revista. As decisões editoriais foram tomadas por pessoas.

SBIS Sociedade Brasileira de Informática em Saúde