

# Classification of Histopathological Images of Breast Cancer Using Convolutional Neural Networks

Bernardo Teixeira de Miranda\*, Pedro Moises de Sousa\*

\*Instituto de Ciências Exatas e Tecnológicas - Universidade Federal de Viçosa - Campus Rio Paranaíba (UFV-CRP)

Rodovia MG230, Km7, Caixa Postal 22 - 38.810-000 - Rio Paranaíba - MG - Brasil

Emails: {bernardo.t.miranda, pedromois} @ufv.br

**Resumo**—Convolutional neural networks (CNNs) play a crucial role in early diagnosis detection, aiding healthcare professionals in decision-making. This study utilizes different CNN architectures (AlexNet, ResNet-50, and EfficientNet) to classify breast cancer histopathological images as benign or malignant, using the BreakHis dataset. The models were trained and evaluated with various magnifications and epochs, measuring the performance of each model based on metrics such as accuracy, recall, and specificity in image classification. The results showed that EfficientNet achieved an average of 98.15%, ResNet-50 reached 98.18%, and AlexNet obtained 95.47%.

**Index Terms**—Convolutional Neural Networks (CNNs), Breast Cancer Detection, Histopathological Image Classification, AlexNet, ResNet-50, EfficientNet, BreakHis, Image Classification.

## I. INTRODUÇÃO

O câncer de mama é uma doença caracterizada pela multiplicação de células anormais na mama, resultando na formação de um tumor com potencial para invadir outros órgãos. Existem várias variações deste tipo de câncer, algumas das quais podem se desenvolver mais rapidamente do que outras. Embora raro, pode afetar homens, representando 1% dos casos [1].

Segundo os dados do INCA [2], foram estimados aproximadamente 73.610 novos casos de câncer de mama em 2023, com uma margem de risco de aproximadamente 66,54 casos para cada 100 mil. O câncer de mama, sendo a principal causa de mortalidade por câncer entre as mulheres no Brasil, apresentou uma taxa de mortalidade ajustada por idade de 11,71 por 100 mil habitantes, resultando em 18.139 óbitos em 2021. As regiões Sul e Sudeste do país registram as maiores taxas de incidência e mortalidade dessa doença.

As estratégias utilizadas para a detecção precoce do câncer de mama incluem diagnóstico e rastreamento. O diagnóstico envolve abordagem a pessoas com sinais/sintomas, enquanto rastreamento visa identificar alterações em populações sem sintomas. No Brasil, as Diretrizes para a Detecção Precoce do câncer de mama, são baseadas em revisão sistemática que orientam profissionais de saúde [3].

A aplicação da tecnologia na medicina tem revelado avanços significativos, especialmente no campo do câncer de mama. Novas ferramentas e técnicas estão sendo constantemente desenvolvidas. Na área da visão computacional, surgem oportunidades para explorar estudos, análises e processamento de características em imagens [4]. Como exemplificado por Tan

et al. [5], que apresenta um estudo de Redes Neurais Convolucionais (CNNs) utilizando Aprendizado Federado (FL) para a classificação de imagens de câncer de mama, e também pelo trabalho de trabalho de Macaço e Neagoe [6], que propõe um novo modelo para a detecção de câncer de mama por meio da termografia e Redes Neurais Convolucionais (CNNs).

Este trabalho propõe a identificação e classificação do câncer de mama utilizando imagens histopatológicas, com o apoio de redes neurais convolucionais. O objetivo principal é fornecer suporte aos profissionais de saúde, facilitando a tomada de decisões e a confirmação de diagnósticos precoces e precisos de câncer de mama.

As seções seguintes deste artigo estão estruturadas da seguinte maneira: A Seção III apresenta uma revisão da literatura atual e analisa pesquisas que se assemelham ao trabalho proposto neste artigo. A Seção IV apresenta os métodos utilizados para a classificação das imagens, bem como as métricas utilizadas para avaliar o desempenho. Na Seção V, temos os resultados obtidos neste trabalho com base nas métricas aplicadas. E finalmente, a Seção VI encerra o artigo com uma discussão das conclusões e oferece observações finais.

## II. REFERENCIAL TEÓRICO

### A. Câncer de Mama

O termo “câncer” abrange uma grande variedade de doenças malignas que são caracterizadas pelo crescimento descontrolado de células que invadem tecidos e órgãos [7]. O câncer de mama é uma condição na qual as células proliferam de forma anormal na mama, resultando na formação de um tumor que pode espalhar para outros órgãos. Existem muitos tipos de variantes para o câncer de mama, alguns se desenvolvem de forma mais rápida do que outros [8].

As imagens histopatológicas são fotografias das células e tecidos removidos de “carços e inchaços” suspeitos obtidos através da biópsia. Essas imagens permitem que os médicos examinem detalhadamente o tecido em busca de alterações nas células que podem indicar doenças. Elas fornecem informações cruciais para identificar condições patológicas, como câncer, e guiar o tratamento adequado aos pacientes [9]. A figura 1 exemplifica como é retirado uma figura histopatológica.




Figura 1. Exemplificação de uma imagem histopatológica adaptada de [10]

### B. Redes Neurais Convolucionais

De maneira semelhante aos processos tradicionais de visão computacional, uma CNN aplica filtros aos dados visuais, preservando as relações de vizinhança entre os *pixels* da imagem durante o processo de rede. Uma rede neural convolucional se baseia-se em vários componentes com tipos de funções diferentes como pode ser observado na Figura 2.




Figura 2. Exemplo de uma rede neural convolucional e suas diferentes camadas adaptada de [11]

A arquitetura de uma Rede Neural Convolucional (CNN) pode ser dividida em várias camadas, cada uma desempenhando um papel específico no processamento e extração de características de uma imagem. Alguns autores, como [12, 13], fornecem uma divisão comum das camadas de uma CNN, que geralmente inclui:

1) *Camada Convolucional (Convolutional Layer)*: Segundo [12], a camada de convolução é uma parte essencial das redes neurais convolucionais (CNNs), onde operações de convolução são executadas para detectar padrões em imagens. Isso é realizado por meio de filtros (*kernels*) que buscam reconhecer características em diferentes partes da imagem, como bordas ou cantos. Cada neurônio na camada de convolução é conectado aos *pixels* da camada anterior, com pesos atribuídos a essas conexões. Esses pesos de correlação nos neurônios funcionam como filtros de convolução no espaço da imagem. O resultado é um mapa de características que mostra os padrões detectados, que são então encaminhados para a próxima camada [11].

Um exemplo de uma camada de convolução pode ser observado na Figura 3.

2) *Camada de Agrupamento (Pooling Layer)*: Após as camadas de convolução é realizado o *pooling*, na qual é aplicada

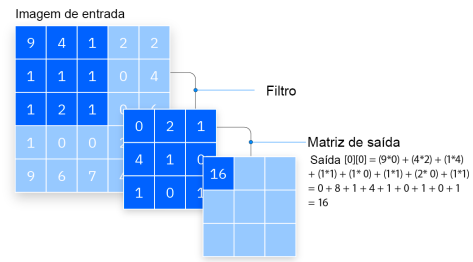


Figura 3. Exemplo de uma Camada Convolucional (*Convolutional Layer*) adaptada de [14]

para reduzir o tamanho da entrada. Ela resume uma região de saída, reduzindo assim a quantidade de amostras isso pode ser visto na Figura 4. Sua aplicação contribui para a preservação das características essenciais em uma representação mais compacta. Entretanto, é importante ressaltar que dependendo do problema específico em consideração a sua eficiência pode variar [12].




Figura 4. Exemplo de um *Max Pool* adaptada de [12]

3) *Camada Totalmente Conectada (Fully Connected Layer)*: Na etapa de camada totalmente conectada em um modelo de rede neural convolucional (CNN), ocorre o processo de tomada de decisão com base nas características extraídas pelas camadas convolucionais e de *pooling*. Nessa fase, as características espaciais são utilizadas para determinar as probabilidades associadas a cada classe, ou seja, o quão bem uma determinada característica se ajusta a cada uma das possíveis classes [12].

Isso ocorre adicionando uma ou mais camadas totalmente conectadas no final, na qual cada neurônio da camada anterior está conectado a todos os neurônios na próxima camada, e cada valor contribui para prever o quanto uma característica corresponde a cada classe. Podemos empilhar essas camadas para aprender características mais complexas. A saída da última camada é direcionada para um classificador. O classificador Softmax atribui probabilidades a cada classe, garantindo que a soma dessas probabilidades seja igual a 1. Por outro lado, o SVM (*Support Vector Machine*) produz escores para cada classe, onde a classe com o escore mais alto é identificada como a predição correta [12].

### III. TRABALHOS RELACIONADOS

No estudo de Parvin e Hasan [15], foi realizada uma análise comparativa de diferentes arquiteturas de redes neurais

convolucionais (CNN), incluindo LeNet-5, AlexNet, VGG-16, ResNet-50 e Inception-v1, aplicadas à classificação de imagens histopatológicas para a detecção de câncer de mama. A pesquisa utilizou o conjunto de dados BreakHis, que contém imagens de biópsias microscópicas de tumores benignos e malignos em várias ampliações. O desempenho dos modelos foi avaliado com base em métricas como precisão, AUC, *recall* e F1-score. Todas as imagens foram redimensionadas para 224x224 *pixels*, com um tamanho de lote de 32 e um *momentum* de 0,9. O treinamento foi realizado por 300 épocas, com uma taxa de aprendizado inicial de 0,01 e o uso de estratégias de aumento de dados para prevenir overfitting. O conjunto de dados foi dividido em 80% para treinamento e 20% para teste. Os resultados mostraram que a arquitetura Inception-v1 obteve o melhor desempenho, alcançando as maiores acurácias de 89%, 92%, 94% e 90%, respectivamente, para os diferentes fatores de ampliação (40X, 100X, 200X e 400X).

Melekoodappattu et al. [16] realizaram uma modificação na arquitetura e nas especificações da rede, para obter um melhor desempenho no diagnóstico de malignidade no tecido mamário. Aplicando o modelo CNN de nove camadas para o diagnóstico de câncer de mama, obteve uma precisão de 97,8% e 98% utilizando o *dataset* MIAS e uma precisão de 98,3% e 97,9% utilizando o *dataset* DDSM. O estudo previamente mencionado busca aprimorar uma arquitetura e especificações proposta no trabalho, o trabalho atual tem como o foco principal em realizar uma avaliação comparativa das CNNs existentes, com um objetivo de identificar quais delas possuem um desempenho melhor entre as demais.

Com base nos estudos de Barbosa. et al. [17], foram implementadas seis redes neurais convolucionais (CNNs) com o uso de aumento de dados nos conjuntos de imagens de câncer de mama (BreakHis e Biglycan). O objetivo foi medir o impacto individual e combinado da otimização e da taxa de aprendizado na precisão de treinamento dos modelos de classificação de imagens de câncer de mama. Foram conduzidos experimentos para avaliar o impacto desses parâmetros, tanto individualmente quanto em seus níveis específicos (0,001 e 0,0001), na precisão de validação. No conjunto de dados BreakHis, o modelo EfficientNet alcançou uma acurácia de 98,86%, enquanto o modelo ShuffleNet obteve uma acurácia de 97,06% no conjunto de imagens do Biglycan, ambos utilizando o otimizador Adam. Por meio dessa abordagem, foi possível analisar o impacto dos fatores de otimização e do *learning rate* na acurácia dos modelos de previsão, com o auxílio de um método parcial.

#### IV. METODOLOGIA

Neste capítulo, será apresentado a metodologia para a realização deste estudo, utilizando dados do *DataSet* BreakHis [10]. Será aplicado três Redes Neurais Convolucionais distintas (CNNs), sendo elas a AlexNet, ResNet-50 e a EfficientNet utilizando com ferramenta a biblioteca *PyTorch* para a implementação e execução dessas redes. A metodologia seguirá o fluxo do diagrama geral ilustrado na Figura 5.

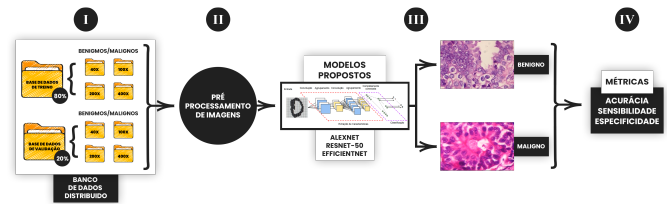


Figura 5. Diagrama Geral da metodologia adaptada de [10] [11]

##### A. Conjuntos de Imagens

1) *BreakHis*: O *dataset* BreakHis [10] é composto por 9.109 imagens microscópicas de tecido tumoral de mama coletadas de 82 pacientes usando diferentes fatores de ampliação (40X, 100X, 200X e 400X). Nelas contém 2.480 amostras benignas e 5.429 malignas com uma resolução de 700x460 *pixels* com um RGB de 3 canais, profundidade de 8 bits em cada canal, do formato PNG. A Figura 6 mostra um exemplo de lâmina de tumor maligno de mama nas diferentes ampliações.




Figura 6. Exemplo de Lâmina de tumor maligno de mama em diferentes tipos de ampliação disponíveis: (a) 40x, (b) 100x, (c) 200x e (d) 400x [10].

##### B. Coleta e Preparação de Dados

Conforme a Figura 5 (I), esta etapa envolve a coleta e organização dos dados da base de dados BreakHis [10], que são essenciais para o treinamento e validação das Redes Neurais Convolucionais (CNNs). Primeiramente, foi feita a coleta das imagens, que foram cuidadosamente organizadas em duas categorias: Benignas e Malignas. Em seguida, foi realizada uma pré-distribuição das imagens, garantindo a mesma quantidade de amostras para ambas as categorias em diferentes ampliações (40x, 100x, 200x e 400x). Dessa forma, foi assegurado que cada categoria possuísse uma distribuição equilibrada de imagens.

Após essa etapa de organização e pré-distribuição, os dados foram divididos para compor os conjuntos de treinamento e validação, sendo 80% do total das imagens destinado ao treinamento e 20% à validação. Podemos analisar na Figura 7

uma exemplificação de como foi realizado a divisão da base de dados.




Figura 7. Exemplificação da preparação dos dados

### C. Pré-Processamento

Seguindo o que está indicado na Figura 5 (II), será aplicado um pré-processamento de imagens, incluindo técnicas de normalização e ajustes nos dados para melhorar a qualidade das entradas para as Redes Neurais Convolucionais (CNNs). A normalização é utilizada para padronizar os valores dos *pixels*, o que pode facilitar a aprendizagem do modelo e aumentar a sua precisão durante a fase de treinamento, garantindo que as CNNs extraíam as características mais importantes das imagens.

### D. Treinamento e Avaliação das Redes Neurais Convolucionais

Nesta etapa, conforme detalhado na Figura 5 (III), será implementada três Redes Neurais Convolucionais distintas (CNNs), sendo elas a AlexNet, ResNet-50 e a EfficientNet com a utilização da biblioteca *PyTorch*. Cada CNN será carregada com pesos pré-treinados no dataset ImageNet, o que oferece uma base inicial de aprendizado para as redes. Em seguida, serão treinadas e avaliadas com foco na capacidade do modelo de classificar as imagens como benignas ou malignas.

Para a execução dos treinamentos, utilizou-se um computador com as seguintes especificações técnicas: uma GPU Nvidia GeForce RTX 4060 Ti com 4GB de memória dedicada, um processador Intel Core i5-4430, e 32 GB de memória RAM DDR3 com frequência de 800 MHz. Assim foram definidos parâmetros básicos no código, incluindo o tamanho do lote (*batch size*) de 32, uma *SEED* de 42, a taxa de aprendizado (*learning rate*) de 0,01 e o momento (*momentum*) de 0,9. Além disso, foram testados três diferentes números de épocas: 50, 100 e 250. Além disso, o critério de perda escolhido foi a função *CrossEntropyLoss*, e o otimizador utilizado foi o *SGD* da biblioteca *PyTorch*.

Durante a pesquisa, foi realizado vários testes para ajustar o tamanho do lote e a taxa de aprendizado, até encontrar os valores mais adequados para alcançar um melhor desempenho. Esses parâmetros foram aplicados da mesma maneira em todos os modelos durante o treinamento e a avaliação, garantindo uma comparação justa dos resultados.

### E. Métricas

Na Figura 5 (IV), foram utilizados métricas importantes, como acurácia, sensibilidade e especificidade, permitindo a identificação do modelo mais eficiente na tarefa de classificação das imagens em benignas e malignas, assim garantindo a precisão na detecção do câncer de mama.

Obtemos a acurácia (ACC), sensibilidade (SE) e especificidade (SP), que são obtidas pelas Equações 1 a 3 conforme os livros de BALAS et al. [18] e o Wani et al. [12]. Essas métricas são necessárias para avaliar a eficácia dos modelos na classificação de imagens em categorias específicas, como benignas e malignas. Para calcular essas métricas, utilizamos as seguintes definições: VP representa o número de verdadeiros positivos, FP o número de falsos positivos, VN o número de verdadeiros negativos e FN o número de falsos negativos.

$$ACC = \frac{(VP + VN)}{(VP + VN + FP + FN)} \quad (1)$$

$$SE = \frac{VP}{(VP + FN)} \quad (2)$$

$$SP = \frac{VN}{(VN + FP)} \quad (3)$$

## V. RESULTADOS E DISCUSSÃO

Inicialmente, foi realizado um teste em 50 épocas utilizando os modelos AlexNet, Resnet-50 e EfficientNet, com os resultados mostrados na Tabela I. Nota-se que o modelo ResNet-50 apresentou maiores valores de acurácia nas ampliações de 100x, 200x e 400x, alcançando, respectivamente, 98,68%, 98,61% e 97,38%. O modelo EfficientNet também obteve um bom desempenho, tendo com melhor resultado em comparação aos demais na ampliação de 40x com 98,88%. Por outro lado, o modelo AlexNet obteve acurácias inferiores em comparação aos demais, não conseguindo superar os resultados dos outros modelos testados.

Tabela I  
RESULTADO DAS MÉTRICAS DE AVALIAÇÃO REALIZADAS POR TODOS OS MODELOS EM DIFERENTES AMPLIAÇÕES 50 ÉPOCAS.

Modelo	Ampliação	ACC (%)	SE (%)	SP (%)
AlexNet	40x	94,68%	95,20%	94,40%
	100x	96,58%	93,02%	98,41%
	200x	95,57%	96,00%	95,34%
	400x	95,04%	94,07%	95,56%
ResNet-50	40x	98,04%	95,20%	99,57%
	100x	<b>98,68%</b>	96,12%	100%
	200x	<b>98,61%</b>	98,40%	98,73%
	400x	<b>97,38%</b>	94,07%	99,11%
EfficientNet	40x	<b>98,88%</b>	97,60%	99,57%
	100x	98,42%	96,12%	99,60%
	200x	97,51%	96,00%	98,31%
	400x	96,79%	95,76%	97,33%



Na sequência, foi realizado um teste de 100 épocas para os mesmos modelos e ampliações. Com base nos resultados mostrados na Tabela II, pode-se observar um aumento nos resultados dos modelos ResNet-50 e EfficientNet, com um destaque para o EfficientNet, que alcançou acurácias de 98,60%, 97,63% e 96,79% nas ampliações de 40x, 100x e 400x, respectivamente. A ResNet-50 se destacou na ampliação de 200x, obtendo uma acurácia de 99,17%. O Modelo AlexNet também apresentou melhorias em relação ao teste de 50 épocas, mas os aumentos não foram significativos o suficiente para superar os demais modelos.

Tabela II  
RESULTADO DAS MÉTRICAS DE AVALIAÇÃO REALIZADAS POR TODOS OS MODELOS EM DIFERENTES AMPLIAÇÕES EM 100 ÉPOCAS.

Modelo	Ampliação	ACC (%)	SE (%)	SP (%)
AlexNet	40x	97,20%	96,00%	97,84%
	100x	96,32%	90,70%	99,20%
	200x	96,68%	94,40%	97,88%
	400x	96,50%	94,92%	97,33%
ResNet-50	40x	98,32%	96,80%	99,14%
	100x	97,11%	93,02%	99,20%
	200x	<b>99,17%</b>	98,40%	99,58%
	400x	95,34%	90,68%	97,78%
EfficientNet	40x	<b>98,60%</b>	97,60%	99,14%
	100x	<b>97,63%</b>	94,57%	99,20%
	200x	98,89%	98,40%	99,15%
	400x	<b>96,79%</b>	97,46%	96,44%

Por fim, foi realizado um teste de 250 épocas para os mesmos modelos e ampliações. A tabela III apresenta os resultados obtidos nessa execução, mostrando um aumento significativo nas acurácias dos modelos ResNet-50 e EfficientNet. Ambos modelos destacaram na ampliação de 200x, onde empataram com uma acurácia de 99,17%. Além disso a ResNet-50 alcançou a acurácia de 98,95% na ampliações de 200x enquanto o EfficientNet obteve acurácias de 99,16% e 97,96% nas ampliações de 40x e 400x, respectivamente. Mais uma vez, o modelo AlexNet não demonstrou melhorias significativas.

A Figura 8 apresenta uma comparação gráfica das acurácias obtidas pelos três modelos em diferentes épocas e ampliações.

Os métodos propostos apresentaram resultados superiores em termos de acurácia quando comparados aos outros estudos, conforme mostrado na Tabela IV. Realizando a média entre os estudos, o modelo AlexNet alcançou uma média da acurácia de 95,47% em no estudo realizado, enquanto o estudo de Parvin e Hasan [15] obteve uma média de 83,25%. Para o modelo ResNet-50, no estudo realizado alcançou uma média de 98,18% enquanto o estudo de Parvin e Hasan [15] atingiu 50,00%. Por fim para o modelo EfficientNet, esse estudo alcançou uma média de 98,15% enquanto o estudo de Ahmad, Asghar e Gillani [19] teve uma média de 95,18%.

Tabela III  
RESULTADO DAS MÉTRICAS DE AVALIAÇÃO REALIZADAS POR TODOS OS MODELOS EM DIFERENTES AMPLIAÇÕES EM 250 ÉPOCAS.

Modelo	Ampliação	ACC (%)	SE (%)	SP (%)
AlexNet	40x	96,92%	95,20%	97,84%
	100x	96,32%	90,70%	99,20%
	200x	96,68%	93,60%	98,31%
	400x	94,75%	90,68%	96,89%
ResNet-50	40x	97,76%	94,40%	99,57%
	100x	<b>98,95%</b>	96,90%	100%
	200x	<b>99,17%</b>	99,20%	99,15%
	400x	95,63%	92,37%	97,33%
EfficientNet	40x	<b>99,16%</b>	98,40%	99,57%
	100x	97,63%	95,35%	98,80%
	200x	<b>99,17%</b>	99,20%	99,15%
	400x	<b>97,96%</b>	98,31%	97,78%




Figura 8. Acurácias dos Modelos

## VI. CONCLUSÃO

Este artigo avaliou a eficácia de três arquiteturas de Redes Neurais Convolucionais (AlexNet, ResNet-50 e EfficientNet) na classificação de imagens histopatológicas de câncer de mama usando a base de dados BreakHis [10]. Os resultados mostraram que o modelo EfficientNet obteve a maior acurácia geral, principalmente em ampliações de 40x e 100x. O modelo ResNet-50 também apresentou ótimos resultados em ampliações de 100x e 200x. Por outro lado, o AlexNet não conseguiu superar o desempenho dos outros modelos, mesmo após o aumento do número de épocas. Os melhores resultados obtidos foram no teste de 500 épocas, na qual o modelo EfficientNet alcançou 99,16%, 97,63%, 99,17% e 97,96% nas ampliações de 40x, 100x, 200x e 400x respectivamente.

Portanto os resultados indicam que os modelos EfficientNet e ResNet-50 são ferramentas promissoras para auxiliar aos profissionais de saúde na classificação de imagens histopatológicas do cancer de mama, assim podendo melhorar os serviços de saúde ao permitir prognósticos mais precisos e auxiliando na tomada de decisões clínicas.

Tabela IV  
COMPARAÇÃO DA ACURÁCIA E SENSIBILIDADE OBTIDA PELOS MÉTODOS PROPOSTOS COM METODOLOGIA DO ESTADO DA ARTE.

		Métodos Propostos					
		Meu modelo		[15], 2020		[19], 2022	
Modelo	Ampliação	Acurácia (%)	Sensibilidade (%)	Acurácia (%)	Sensibilidade (%)	Acurácia (%)	Sensibilidade (%)
AlexNet	40x	94,68%	95,20%	80,00%	80,00%	-	-
	100x	96,58%	93,02%	83,00%	83,00%	-	-
	200x	95,57%	96,00%	85,00%	85,00%	-	-
	400x	95,04%	94,07%	85,00%	85,00%	-	-
ResNet-50	40x	98,04%	95,20%	50,00%	50,00%	-	-
	100x	98,68%	96,12%	50,00%	50,00%	-	-
	200x	98,61%	98,40%	50,00%	50,00%	-	-
	400x	97,38%	94,07%	50,00%	50,00%	-	-
EfficientNet	40x	98,88%	97,60%	-	-	96,99%	96,01%
	100x	98,42%	96,12%	-	-	95,39%	93,18%
	200x	97,51%	96,00%	-	-	94,71%	91,63%
	400x	96,79%	95,76%	-	-	93,62%	93,01%

Para trabalhos futuros, queremos implementar a filtragem Wavelet para melhorar a precisão dos modelos. Também planejamos adicionar um mapa de calor para mostrar, de forma mais clara, quais áreas das imagens o modelo considera importantes na hora de fazer a classificação.

## VII. AGRADECIMENTOS

Este estudo foi financiado em parte pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001. Bernardo Teixeira de Miranda recebeu uma bolsa do PIBIC/FURNABIC/CNPq.

## REFERÊNCIAS

- [1] “Câncer de mama,” Instituto Nacional de Câncer - INCA, 2023, acessado em 15 de julho de 2024. [Online]. Available: <https://www.gov.br/inca/pt-br/assuntos/cancer/tipos/mama>
- [2] “Outubro rosa 2023,” Instituto Nacional de Câncer - INCA, 2023, acessado em 15 de julho de 2024. [Online]. Available: <https://www.gov.br/inca/pt-br/assuntos/campanhas/2023/outubro-rosa>
- [3] “Detecção precoce,” Instituto Nacional de Câncer - INCA, 2023, acessado em 15 de julho de 2024. [Online]. Available: <https://www.gov.br/inca/pt-br/assuntos/gestor-e-profissional-de-saude/controlado-cancer-de-mama/acoes/deteccao-precoce>
- [4] P. C. R. Boasquevisque, “Classificação do grau histológico de malignidade em câncer de mama utilizando programas de análise automatizada de imagens e aprendizado de máquina,” Ph.D. dissertation, Brasil, 2020.
- [5] Y. N. Tan, V. P. Tinh, P. D. Lam, N. H. Nam, and T. A. Khoa, “A transfer learning approach to breast cancer classification in a federated learning framework,” *IEEE Access*, vol. 11, pp. 27 462–27 476, 2023.
- [6] I.-R. Macaioi and V.-E. Neagoe, “Breast cancer detection using thermal infrared image analysis based on dempster-shafer decision fusion of cnn classifiers,” in *2023 15th International Conference on Electronics, Computers and Artificial Intelligence (ECAI)*, 2023, pp. 01–06.
- [7] “O que é câncer?” Instituto Nacional de Câncer - INCA, 2022, acessado em 15 de julho de 2024. [Online]. Available: <https://www.gov.br/inca/pt-br/assuntos/cancer/o-que-e-cancer>
- [8] “Câncer de mama: vamos falar sobre isso?” Instituto Nacional de Câncer - INCA, 2023, acessado em 15 de julho de 2024. [Online]. Available: [https://www.inca.gov.br/sites/ufu.sti.inca.local/files/media/document/cartilha\\_cancer\\_de\\_mama\\_2022\\_visualizacao.pdf](https://www.inca.gov.br/sites/ufu.sti.inca.local/files/media/document/cartilha_cancer_de_mama_2022_visualizacao.pdf)
- [9] D. R. Brown. (2024) Histopathology. Acessado em 16 de julho de 2024. [Online]. Available: <https://www.rcpath.org/discover-pathology/news/fact-sheets/histopathology.html>
- [10] “Breast cancer histopathological database (breakhis),” BreakHis, 2023, acesso em 23 de outubro de 2023. [Online]. Available: <https://web.inf.ufpr.br/vri/databases/breast-cancer-histopathological-database-breakhis/>
- [11] A. C. G. Vargas, A. Paes, and C. N. Vasconcelos, “Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres,” in *Proceedings of the xxix conference on graphics, patterns and images*, vol. 1, no. 4, sn, 2016.
- [12] M. A. Wani, F. A. Bhat, S. Afzal, and A. I. Khan, *Advances in Deep Learning*, 1st ed., ser. Studies in Big Data. Springer Singapore, 2020. [Online]. Available: <https://doi.org/10.1007/978-981-13-6794-6>
- [13] C. C. Aggarwal *et al.*, *Neural networks and deep learning*. Springer, 2018, vol. 10, no. 978.
- [14] “Convolutional neural networks,” IBM, 2024. [Online]. Available: <https://www.ibm.com/topics/convolutional-neural-networks>
- [15] F. Parvin and M. A. M. Hasan, “A comparative study of different types of convolutional neural networks for breast cancer histopathological image classification,” in *2020 IEEE Region 10 Symposium (TENSYP)*. IEEE, 2020, pp. 945–948.
- [16] J. G. Melekoodappattu, A. S. Dhas, B. K. Kandathil, and K. Adarsh, “Breast cancer detection in mammogram: Combining modified cnn and texture feature based approach,” *Journal of Ambient Intelligence and Humanized Computing*, vol. 14, no. 9, pp. 11 397–11 406, 2023.
- [17] G. Barbosa., L. Moreira., P. Moises de Sousa., R. Moreira., and A. Bakes., “Optimization and learning rate influence on breast cancer image classification,” in *Proceedings of the 19th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications - Volume 3: VISAPP, INSTICC*. SciTePress, 2024, pp. 792–799.
- [18] V. E. Balas, S. S. Roy, D. Sharma, and P. Samui, Eds., *Handbook of Deep Learning Applications*, 1st ed., ser. Smart Innovation, Systems and Technologies. Springer Cham, 2019. [Online]. Available: <https://doi.org/10.1007/978-3-030-11479-4>
- [19] N. Ahmad, S. Asghar, and S. A. Gillani, “Transfer learning-assisted multi-resolution breast cancer histopathological images classification,” *The Visual Computer*, vol. 38, no. 8, pp. 2751–2770, 2022.