

Breast Density Classification Using Convolutional Neural Networks and Analysis of the CLAHE Technique

Luana Amie Shimomaebara Nishida¹, Pedro Moises de Sousa¹

¹Instituto de Ciências Exatas e Técnicas - Universidade Federal de Viçosa - Campus Rio Paranaíba (UFV-CRP)

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

luana.nishida@ufv.br, pedromoises@ufv.br

Abstract—Breast cancer is the most common type of cancer and one of the leading causes of death worldwide. Early detection is essential to increase the chances of successful treatment, but current conventional methods still have limitations. Artificial intelligence has shown promise in aiding diagnosis. The project therefore seeks to use Convolutional Neural Networks to classify breast density, which is an important factor in the diagnosis of breast cancer. These networks learn automatically from raw data, classifying more accurately. The convolution operation and pooling layers are used to process the inputs and extract complex features. Fully connected layers classify and identify features. The dataset used was a combined dataset between INbreast and RSNA, pre-processed and using the CLAHE technique to increase the contrast of the mammograms. The end result was an accuracy of 89.29% for ResNet-50 and ShuffleNet.

Index Terms—Breast cancer, mammograms, convolutional neural network, Artificial intelligence, CLAHE technique

I. INTRODUÇÃO

O câncer de mama é uma doença causada pela multiplicação de células anormais da mama de forma desordenada, possibilitando o desenvolvimento de um tumor com potencial para invadir outros órgãos [1]. Mundialmente é o tipo de câncer de principal causa global de incidência [2]. Entretanto, quando detectado em fases iniciais, diminui a necessidade de tratamentos mais agressivos e aumenta-se a chance de se obter resultados mais satisfatórios [3].

Atualmente, o Ministério da Saúde recomenda que seja feita a mamografia de rastreamento, exame de radiografia das mamas realizado para identificar possíveis alterações suspeitas de câncer antes mesmo dos sintomas [3]. No entanto, apesar da mamografia auxiliar na detecção precoce, ainda há uma limitação para diagnosticar mamas densas, visto que a densidade mamária influencia diretamente na qualidade do exame e na exatidão do diagnóstico [4]. Além disso, as taxas de falsos positivos e falsos negativos ainda são altas [3], causando o interrompimento do processo de detecção, atrapalhando o tratamento e consequentemente aumentando as taxas de mortalidade por câncer de mama.

Um dos fatores de risco para o câncer de mama é a densidade mamográfica, mamas mais densas tem risco de quatro a seis vezes mais de desenvolver câncer em comparação à mamas mais gordurosas [5]. Portanto o grau de densidade da mama é uma característica importante para o laudo, e apesar

de existir o atual sistema de padronização BI-RADS™ (*Breast Imaging-Reporting and Data System*) [6], a avaliação se torna subjetiva por depender da qualidade dos exames, de fatores fisiológicos e da experiência profissional do analista [4].

Como possível solução para os riscos de resultados incorretos na detecção, a tecnologia surge como um potencial auxiliar de um diagnóstico mais preciso e eficaz. Um exemplo a ser citado é o estudo de Boujemaa et al. [7] que tem por objetivo analisar a eficácia das redes neurais artificiais para a classificação de densidade mamária. Foi utilizado um conjunto de dados com 219 pacientes e um modelo treinado baseado na Rede Neural *Multi-Layer Perceptron* para classificar entre mama densa e mama não densa. Os resultados mostraram um alto nível de acurácia, com uma área sob a curva (AUC) de 0,998, concluindo que a previsão de densidade mamária através de redes neurais é eficaz. Logo, o uso de tecnologias como rede neurais tem a capacidade de ajudar no diagnóstico do câncer de mama, tendo em vista as atuais limitações de detecção em mamas densas e o risco que a densidade mamária traz às mulheres.

Assim, o trabalho tem como objetivo desenvolver uma ferramenta de apoio à decisão, no caso de identificar a densidade de tecidos mamários. Classificando em mama densa ou não densa, a partir de mamografias, a fim de ajudar na detecção do câncer de mama, utilizando redes neurais convolucionais (CNNs) da literatura, tais como a *DenseNet-121* [8], *ResNet-50* [9] e a *ShuffleNet* [10].

Este artigo está estruturado da seguinte forma: A Seção II apresenta o referencial teórico, oferecendo uma contextualização sobre o tema e discutindo questões relevantes para o desenvolvimento da pesquisa. A Seção III realiza uma revisão da literatura sobre trabalhos relacionados à detecção e classificação de densidade mamária. A Seção IV descreve a metodologia empregada, detalhando os métodos utilizados na pesquisa. A Seção V expõe os resultados obtidos, enquanto a Seção VI encerra o artigo com a discussão e conclusão, considerando tanto as questões abordadas quanto os resultados alcançados.

II. REFERENCIAL TEÓRICO

2.1 Densidade Mamária

A quantidade de tecido fibroglandular (fibroblastos, células epiteliais e tecido conjuntivo denso) de uma mama corresponde ao seu grau de densidade [5]. Ou seja, a densidade mamária se refere à composição da mama, e pode estar relacionada a fatores hormonais, genéticos, idade e índice de massa corporal [11].

Diversos estudos realizados mostraram a relação direta entre a densidade mamária e o risco de câncer de mama. No estudo, Boyd et al. [12] descreve a associação entre a densidade dos tecidos mamários na mamografia e o risco subsequente de câncer de mama, demonstrando que mulheres com mais de 75% de densidade mamária possuem maior risco em comparação a mulheres com menos de 10%. Além disso, a mamografia tem uma sensibilidade menor para mamas mais densas, isso se deve ao fato de que grande parte dos nódulos apresentam densidade semelhante ao tecido fibroglandular. Dificultando a identificação de lesões mamárias em mamas com maior porcentagem de tecido fibroglandular (mamas mais densas) [13]. A padronização BI-RADS™ mais recente para descrever a densidade mamária dos exames se dá pela Figura 1:

DENSIDADE	DESCRIÇÃO DAS MAMAS
A	Predomínio de tecido gorduroso
B	Presença de áreas densas esparsas
C	Heterogeneamente densas
D	Extremamente Densas

Figura 1: Padronização de densidade de acordo com BI-RADS™.

Na Figura 2 é apresentado a visualização dos exames de cada tipo de densidade.

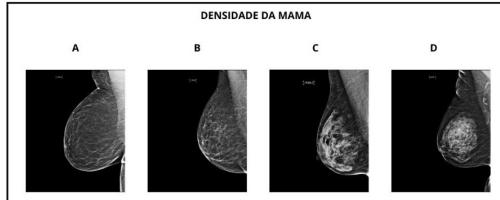


Figura 2: Densidade A se refere ao predomínio de tecido gorduroso, densidade B é descrito como presença de áreas densas esparsas, C significa heterogeneamente densas e D extremamente densas.

2.2 Técnica CLAHE

CLAHE(Contrast-Limited Adaptive Histogram Equalization) [14] é uma técnica de processamento de imagem usada para aprimorar o contraste local. Ao invés de aplicar a equalização em toda a imagem, a CLAHE trabalha em pequenas áreas chamadas "tiles" (ou blocos). A equalização é

feita separadamente em cada bloco, o que ajuda a evitar que o contraste em áreas homogêneas seja exagerado e amplifique o ruído presente na imagem [14]. A Figura 3 apresenta a comparação entre a imagem sem CLAHE na esquerda e com CLAHE no lado direito.

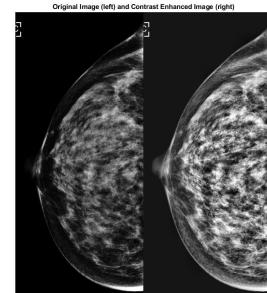


Figura 3: Exemplo da aplicação de CLAHE

2.3 Modelos de Arquiteturas

Neste trabalho foram utilizados três modelos de arquitetura de *CNNs*, *ResNet-50*, *ShuffleNet* e *DenseNet-121*, com o intuito de comparar os desempenhos dos modelos.

- 1) *ResNet-50*: A *ResNet-50* é uma versão da *ResNet* composta por 50 camadas. A arquitetura *ResNet* (*Residual Networks*) foi proposta por He et al. [9] e revolucionou o campo de redes neurais profundas (*deep learning*) ao introduzir conexões residuais, como "atalhos", que permitem treinar sem que o problema de degradação do gradiente ocorra.
- 2) *ShuffleNet*: *ShuffleNet*, proposto por Zhang et al. [10], é uma arquitetura leve e eficiente que foi desenvolvida para dispositivos com recursos limitados. A *ShuffleNet* utiliza duas técnicas principais para alcançar alta eficiência: a primeira é a divisão de convoluções em grupos (*grouped convolutions*), o que reduz significativamente o número de operações; a segunda é a operação de *shuffle* (embaralhamento), que permite uma mistura de canais entre grupos, melhorando a comunicação entre diferentes partes da rede sem aumentar a complexidade computacional.
- 3) *DenseNet-121*: A arquitetura *DenseNet* (*Densely Connected Convolutional Networks*), introduzida por Huang et al. [8], é caracterizada por suas conexões densamente conectadas, onde cada camada recebe como entrada o mapa de características de todas as camadas anteriores e passa suas características para todas as camadas subsequentes. Isso resulta em uma reutilização extrema de características e uma melhoria significativa na eficiência do uso de parâmetros. A *DenseNet-121* é uma variante que possui 121 camadas e é conhecida por sua alta

eficiência em termos de parâmetros e desempenho em comparação com outras arquiteturas profundas.

III. TRABALHOS RELACIONADOS

Diversos estudos têm se desenvolvido com base em aplicações de inteligência artificial para uma maior precisão na medicina, com foco na densidade da mama.

O trabalho de Matsuyama et al. [15] tem como objetivo avaliar um novo modelo de DCNN (*Deep Convolutional Neural Network*) baseado em Transformada *Wavelet* Discreta para classificar densidade mamária. Além de analisarem de forma analítica a confiabilidade do modelo e seu comportamento. A base de dados utilizada é uma base pública e tem 1300 imagens do tipo DICOM, adquirida no TCIA (*The Cancer Imaging Archive*). Foi feita uma extração da informação espectral das imagens utilizando a Transformada *Wavelet* Discreta Redundante Bidimensional (2D-RDWT). O modelo de arquitetura utilizado foi o *ResNet-50* modificado e ajustado com alguns algoritmos e coeficientes *wavelets*, foram construídos dois modelos, um utilizando Transformada *Wavelets* e outro com as imagens originais para serem comparados. São implementados métodos para avaliar a calibração de confiança dos modelos, como diagramas de fiabilidade baseados nas pontuações de previsão do modelo e t-SNE (*t-distributed stochastic neighbor embedding*) para analisar os comportamentos do modelo. Também é feito um cálculo da ambiguidade da classificação utilizando a entropia para calcular a ambiguidade das previsões dos modelos e utiliza-se o *Grad-CAM* para localizar as regiões das imagens mais importantes e que geram maior impacto nas previsões. A acurácia obtida foi de 0,922 para o modelo utilizando *wavelets* e 0,915 para o modelo original. Os resultados mostram que o modelo proposto (utilizando *wavelets*) pode demonstrar não só uma elevada acurácia, mas também uma elevada fiabilidade e interpretabilidade em comparação com o modelo original.

No estudo Mei-Ling Huang e Ting-Yu Lin [16] combina densidade mamária com massas benignas e malignas para classificar tumores de mama. Foi utilizado a base de dados *INbreast*, de 410 imagens foram selecionadas 106 apenas, as imagens originais eram do tipo DICOM e foram convertidas para PNG usando o *Matlab R2019a*. Com aumento de dados e uma técnica de melhoramento de contraste local chamada CLAHE para o pré-processamento, os modelos de redes neurais convolucionais usados foram *AlexNet*, *DenseNet* e *ShuffleNet*, para classificar. E então as acuráncias dos três modelos antes e depois do aumento de dados foram comparadas. Antes, as acuráncias dos conjuntos de teste da *AlexNet* eram de 38,57%, as da *DenseNet* eram de 46,39%, e as da *ShuffleNet* eram de 42,86%. Após o aumento de dados, as acuráncias dos conjuntos de teste do *AlexNet* foram de 95,46%, as da *DenseNet* foram de 99,72%, e as da *ShuffleNet* de 97,84 %. O aumento dos dados permite que o modelo aprenda mais imagens de diferentes situações e ângulos para classificar com precisão novas imagens. Embora a acurácia da *DenseNet* tenha sido a mais elevada, o tempo de execução necessário foi consideravelmente mais longo do que o necessário para a

ShuffleNet. Tendo em conta a acurácia e o tempo de execução, recomenda-se a utilização da *ShuffleNet* na classificação de tumores mamários benignos e malignos em mamografia.

No artigo Saffari et al. [17] têm como objetivo desenvolver um sistema de segmentação e classificação do tecido mamário totalmente automatizado e digitalizado usando técnicas avançadas de aprendizagem profunda. Utiliza-se a base de dados *INbreast*, com 410 imagens de 115 pacientes, com aplicação da rede *conditional Generative Adversarial Networks* (cGAN) para a segmentação de tecidos mamários em mamografias. Foi proposto uma rede neural convolucional para classificar mamografias com base na padronização do *Breast Imaging-Reporting and Data System* (BI-RADS). Foi obtido uma acurácia, precisão, sensibilidade e especificidade de 98%, 97,85%, 97,85% e 99,28%, respectivamente. Os resultados mostram que as técnicas propostas podem produzir uma ferramenta assistida por computador clinicamente útil para análise da densidade mamária por mamografia digital.

IV. METODOLOGIA

Para se obter bons resultados do modelo proposto, todas as etapas, desde a coleta de dados até o treinamento dos dados é de extrema importância, a Figura 4 representa essas etapas.

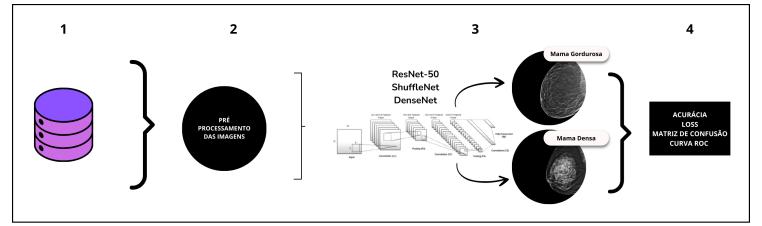


Figura 4: Etapas da metodologia

A. Banco de dados

Foi pesquisado conjuntos de dados públicos considerados com potencial para o problema proposto. O conjunto de dados utilizado no treinamento e validação do presente projeto foi uma combinação entre o *INbreast* [18] e o RSNA (*radiological society of north america*) [19] como mostrado na Figura 6. O *INbreast* foi obtido em um centro hospitalar em Portugal, as mamografias são dimensionadas em 3328×4084 ou 2560×3328 pixels, dependendo da compressão da mama, de acordo com o tamanho da mama da paciente. Um dos fatores positivos desse banco de dados [18] é o fato de ele estar disponível com um relatório que contém os laudos dos exames de cada imagem, elaborados por radiologistas experientes em leitura duplo-cega. Assim, dependendo da aplicação, é possível separar as imagens por presença ou ausência de lesão, tipo de lesão, classificação BI-RADS, densidade mamária, entre outros [18]. O conjunto de dados possui 410 imagens de 115 pacientes diferentes e são no formato DICOM. A outra base de dados utilizada neste trabalho, RSNA, é de uma competição do *Kaggle* [20], possui 54.713 imagens em formato DICOM compactado, de cerca de 11.000 pacientes, acompanhado de uma tabela csv com as informações dos exames. A tabela

informa se é mama direita ou esquerda, posicionamento para incidência sendo craniocaudal (CC), ou mediolateral-obliqua (MLO), idade do paciente, se é câncer ou não, classificação por BI-RADS e densidade.

B. Pré-processamento

O pré-processamento dos dados envolve a definição dos parâmetros do banco de dados, padronização, métodos de inclusão, exclusão e formatação, para que seja possível criar uma base de dados mais adequada. Primeiro as imagens que estavam compactadas foram descompactadas e convertidas de DICOM para PNG. Foi recortado o fundo dessas imagens e feita a conversão para 16 bits. As imagens foram divididas pela densidade mamária a partir da padronização BI-RADS™. Algumas imagens da base de dados RSNA que tinham um conteúdo de 0KB, e que não haviam informações correspondentes foram excluídas do conjunto, prevalecendo apenas aquelas que foram consideradas adequadas para a classificação. Após esse processo, foi utilizado a técnica CLAHE a fim de aumentar o contraste das imagens, favorecendo para um maior detalhamento. Além disso as imagens de entrada foram redimensionadas para 256x256 e normalizadas. A Figura 5 apresenta a mesma imagem em diferentes fases do pré-processamento.

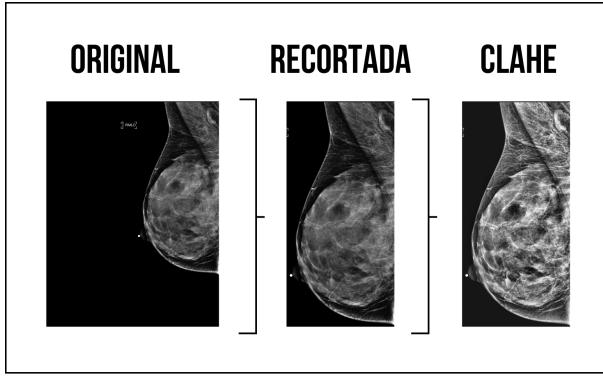


Figura 5: Pré-processamento das imagens: Imagem original, imagem com o fundo recortado e imagem com a aplicação de CLAHE após o recorte do fundo

C. Distribuição da base de dados

Para o treinamento e validação do modelo foram selecionadas 252 imagens da base de dados *INbreast* e 160 imagens da base de dados RSNA, totalizando 412 imagens. Sendo 210 mamografias de alta densidade mamária e 210 de baixa densidade mamária. O conjunto de dados é dividido em 80% para treinamento e 20% para validação, como apresentado na Figura 6.

Portanto de 412 imagens, 328 são para treinamento e 84 são para validação, divididas em 2 classes, Mama Densa e Mama Não Densa. Para o teste do modelo são selecionadas outras 60 imagens da base de dados RSNA diferentes dos exames utilizados na parte de treinamento e validação.

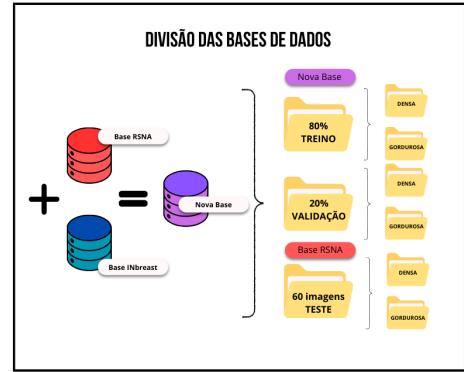


Figura 6: Distribuição da base de dados

D. Treinamento do modelo

No treinamento utilizou de duas bases de dados diferentes combinadas. O conjunto de dados *INbreast* divide a densidade mamária em 4 categorias de acordo com a quarta edição do BI-RADS™, que vão de 1, para baixa densidade (tecido adiposo ou gorduroso), à 4, para densidade muito alta (tecido denso). Foram selecionadas as imagens que possuem valores da coluna ACR (*American College of Radiology*) [21] 1 e 2 para serem classificados como mama não densa, e os valores 3 e 4 para serem classificados como mama densa. No conjunto de dados RSNA a densidade mamária é identificada de acordo com a edição mais recente da padronização BI-RADS™, optou-se por usar exames de densidade A e D para serem classificados como não densa e densa, respectivamente. O treinamento foi feito utilizando os modelos *ResNet-50*, *ShuffleNet* e *DenseNet-121* a fim de comparar os resultados entre eles.

Primeiramente os modelos foram treinados com *Pytorch* [22] em 200 épocas com as bases de dados pré-processadas sem CLAHE, e após a aplicação de CLAHE nas bases de dados os modelos foram treinados novamente em 200 épocas. Foi determinado um *seed* de 42, um *batch size* de 21 e utilizado o otimizador *Adam* com um critério de função de perda *Cross Entropy Loss* [22].

E. Validação e Teste do modelo

Na validação foram utilizados os 20% do conjunto de dados combinados entre *INbreast* e RSNA e a parte de teste foi feita com 60 imagens da base RSNA. Para a avaliação da capacidade do modelo de extrapolar o conhecimento aprendido durante o treinamento, a validação e o teste são realizados utilizando-se de métricas para mensurar o desempenho do classificador e avaliar os erros cometidos. As métricas utilizadas são Precisão, *Recall*, Matriz de Confusão, Acurácia e *Loss* [23] [24].

As métricas de acurácia, precisão e recall utilizadas são descritas a seguir [25], considerando valores VP (Verdadeiros Positivos), VN (Verdadeiros Negativos), FP (Falsos Positivos) e FN (Falsos Negativos).

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN}$$

$$\text{Precisão} = \frac{\text{VP}}{\text{VP} + \text{FP}}$$

$$\text{Recall} = \frac{\text{VP}}{\text{VP} + \text{FN}}$$

F. Ambiente Computacional

O PC (*Personal Computer*) utilizado no trabalho é um *notebook* com uma *CPU Intel(R) Core(TM) i5-1035G1* a 1.00 GHz e 8 GB de *RAM*, rodando *Windows 10* equipado com uma *GPU NVIDIA GeForce MX130*. Os modelos pré-treinados *ResNet-50*, *ShuffleNet* e *DenseNet-121* foram obtidos do *torchvision*. O desenvolvimento dos modelos foi realizado com *Python 3.9*, *PyTorch 2.3.1*, *torchvision 0.18.1* com *CUDA Toolkit 11.8* e *Scikit-learn 1.5.0*.

V. RESULTADOS E DISCUSSÃO

Como resultado da validação foi obtida acurácia de 89,29%, 89,29% e 88,10% do modelo treinado com imagens pré-processadas sem o uso de CLAHE, resultando das seguintes arquiteturas, *ResNet-50*, *ShuffleNet* e *DenseNet-121* respectivamente, representado na Tabela I.

TABELA I

Sem aplicação da CLAHE			
Métricas	ResNet-50	ShuffleNet	DenseNet-121
Acurácia	89.29%	89.29%	88.10%
Precisão	90%	89%	88%
Recall	89%	89%	88%

Após a aplicação da técnica CLAHE ao invés da acurácia aumentar foi apresentado uma diminuição significativa na acurácia dos modelos, como mostra na Tabela II. Obtendo 51,19% como acurácia para as três arquiteturas utilizadas.

TABELA II

Com aplicação da CLAHE			
Métricas	ResNet-50	ShuffleNet	DenseNet-121
Acurácia	51.19%	51.19%	51.19%
Precisão	75%	75%	75%
Recall	51%	51%	51%

A comparação dos modelos foi feita como mostra no gráfico da Figura 7, analisando principalmente as acurácias.

VI. CONCLUSÃO

A partir dos resultados obtidos foi comparado e observado que ambas as arquiteturas utilizadas tiveram um resultado razoável e parecido. A melhor acurácia foi obtida pelo *ResNet-50* e *ShuffleNet*, enquanto a *DenseNet-121* apresentou uma acurácia mais baixa. Além disso, a comparação entre as imagens pré-processadas com e sem CLAHE, mostraram que, em alguns casos, a técnica não contribui positivamente para a melhoria das características relevantes para a classificação. A CLAHE foi aplicada para melhorar o contraste das imagens e potencialmente aumentar a acurácia do modelo, no entanto, observou-se um resultado contrário ao esperado e pode ser atribuído a vários fatores.

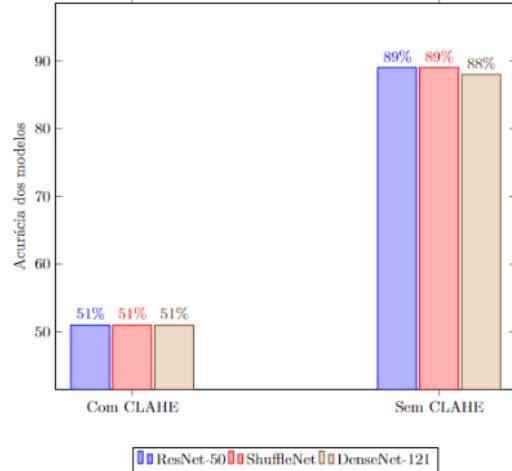


Figura 7: Gráfico de comparação entre os modelos treinados sem a aplicação, e com a aplicação da técnica CLAHE

A configuração dos parâmetros da CLAHE pode ter influenciado negativamente o desempenho. Ajustes no ‘*clipLimit*’ e no ‘*tileGridSize*’ são essenciais para evitar o exagero no contraste e a introdução de ruído. É possível também que a técnica tenha exacerbado algumas características de fundo, tornando o modelo mais suscetível ao ruído.

Como foi abordado na Seção III, o trabalho de Mei-Ling Huang e Ting-Yu Lin também obteve acuráncias baixas antes do uso de aumento de dados, apesar da utilização da CLAHE no pré-processamento. Indicando que a combinação da CLAHE com um conjunto de dados maior, ou utilização de aumento de dados, pode ser mais eficaz. Logo o tamanho da base de dados utilizada no trabalho pode ser um dos fatores para a baixa acurácia obtida.

Portanto, tendo em vista a importância da densidade mamária para o diagnóstico de câncer de mama, é fundamental que a classificação de densidade seja cada vez mais estudada a fim de tornar o diagnóstico mais preciso, rápido e eficaz. O uso de tecnologias inovadoras como redes neurais convolucionais em *deep learning* potencializa ainda mais as pesquisas nessa área, abrindo mais caminhos para a solução. Analisando os resultados obtidos conclui-se que o ajuste dos parâmetros da CLAHE são cruciais para a eficácia da técnica, e considera a combinação e utilização de outras técnicas de pré-processamento, revelando a necessidade de uma análise mais aprofundada em um conjunto de dados maior e estudos futuros.

VII. AGRADECIMENTOS

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Finance Code 001. Luana Amie Shimomaebara Nishida received a scholarship from PIBIC/CNPq

REFERENCES

- [1] INCA. (2022) Câncer de mama: Introdução. Acesso em: 15, junho de 2023. [Online]. Available: <https://www.gov.br/inca/pt-br/assuntos/cancer/tipos/mama>
- [2] ——. (2023) Síntese de resultados e comentários. Acesso em: 15, junho de 2023. [Online]. Available: <https://www.gov.br/inca/pt-br/assuntos/cancer/numeros/estimativa/sintese-de-resultados-e-comentarios>
- [3] ——. (2022) Câncer de mama: Detecção precoce. Acesso em: 15, junho de 2023. [Online]. Available: <https://www.gov.br/inca/pt-br/assuntos/cancer/tipos/mama>
- [4] P. C. Carneiro *et al.*, “Classificação mamográfica por densidade mamária utilizando atributos de intensidade e textura,” 2015.
- [5] N. G. de Lira Soares, K. Y. Gushiken, G. R. Freitas, A. A. M. Joaquim, and G. O. Rodrigues, “Fatores influentes na densidade mamográfica e seu impacto no câncer de mama,” *Brazilian Journal of Health Review*, vol. 6, no. 1, pp. 1222–1238, 2023.
- [6] C. D’Orsi, E. Sickles, E. Mendelson, and E. Morris, *2013 ACR BI-RADS Atlas: Breast Imaging Reporting and Data System*. American College of Radiology, 2014. [Online]. Available: <https://books.google.com.br/books?id=nhWSJwEACAAJ>
- [7] S. Boujemaa, Y. Bouzekraoui, and F. Bentayeb, “Predicting mammographic breast density assessment using artificial neural networks,” *Iranian Journal of Medical Physics/Majallah-I Fizik-I Pizishk-I Īrān*, vol. 21, no. 1, 2024.
- [8] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, “Densely connected convolutional networks,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 4700–4708.
- [9] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 770–778.
- [10] X. Zhang, X. Zhou, M. Lin, and J. Sun, “Shufflenet: An extremely efficient convolutional neural network for mobile devices,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2018, pp. 6848–6856.
- [11] V. Saudável, “Densidade mamária,” 2024, acesso em: 13, agosto de 2024. [Online]. Available: <https://vidasaudavel.einstein.br/mamadensa/#:~:text=Ou%20seja,%20a%20densidade%20mamria,tecido%20fibroglandular%20do%20que%20adiposo>
- [12] N. F. Boyd, H. Guo, L. J. Martin, L. Sun, J. Stone, E. Fishell, R. A. Jong, G. Hislop, A. Chiarelli, S. Minkin *et al.*, “Mammographic density and the risk and detection of breast cancer,” *New England journal of medicine*, vol. 356, no. 3, pp. 227–236, 2007.
- [13] R. N. M. Figueira, Â. I. d. Santos, M. E. Camargo, and H. A. Koch, “Fatores que influenciam o padrão radiológico de densidade das mamas,” *Radiologia Brasileira*, vol. 36, pp. 287–292, 2003.
- [14] K. Zuiderveld, “Viii.5. - contrast limited adaptive histogram equalization,” in *Graphics Gems*, P. S. Heckbert, Ed. Academic Press, 1994, pp. 474–485. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/B9780123361561500616>
- [15] E. Matsuyama, M. Takehara, N. Takahashi, and H. Watanabe, “A breast density classification system for mammography considering reliability issues in deep learning,” *Open Journal of Medical Imaging*, vol. 13, no. 3, pp. 63–83, 2023.
- [16] M.-L. Huang and T.-Y. Lin, “Considering breast density for the classification of benign and malignant mammograms,” *Biomedical Signal Processing and Control*, vol. 67, p. 102564, 2021. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1746809421001610>
- [17] N. Saffari, H. A. Rashwan, M. Abdel-Nasser, V. Kumar Singh, M. Arenas, E. Mangina, B. Herrera, and D. Puig, “Fully automated breast density segmentation and classification using deep learning,” *Diagnostics*, vol. 10, no. 11, p. 988, 2020.
- [18] I. C. Moreira, I. Amaral, I. Domingues, A. Cardoso, M. J. Cardoso, and J. S. Cardoso, “Inbreast: toward a full-field digital mammographic database,” *Academic radiology*, vol. 19, no. 2, pp. 236–248, 2012.
- [19] Kaggle, “Rsnsa breast cancer detection - data,” 2024, acesso em: 13, agosto de 2024. [Online]. Available: <https://www.kaggle.com/competitions/rsnsa-breast-cancer-detection/data>
- [20] ——, “Kaggle: Your machine learning and data science community,” 2024, acesso em: 17, agosto de 2024. [Online]. Available: <https://www.kaggle.com/>
- [21] American College of Radiology, “Bi-rads: Reporting and data systems,” 2024, acesso em: 17, agosto de 2024. [Online]. Available: <https://www.acr.org/Clinical-Resources/Reporting-and-Data-Systems/Bi-Rads>
- [22] A. Paszke, S. Gross, F. Massa, A. Lerer, J. Bradbury, G. Chanan, T. Killeen, Z. Lin, N. Gimelshein, L. Antiga, A. Desmaison, A. Kopf, E. Yang, Z. DeVito, M. Raison, A. S. Tejani, S. Chilamkurthy, B. Steiner, L. Fang, J. Bai, and S. Chintala, “Pytorch: An imperative style, high-performance deep learning library,” *Advances in Neural Information Processing Systems*, vol. 32, 2019. [Online]. Available: <https://pytorch.org/>
- [23] M. A. Wani *et al.*, *Advances in Deep Learning*. Springer, 2020, vol. 57. [Online]. Available: <https://doi.org/10.1007/978-981-13-6794-6>
- [24] M. A. Nielsen, *Neural Networks and Deep Learning*. San Francisco, CA, USA: Determination Press, 2015.
- [25] J. V. Savietto, “Machine learning: Métricas, validação cruzada, bias e variância,” 2024, acesso em: 17, agosto de 2024. [Online]. Available: <https://medium.com/@jvsavietto6/machine-learning-m%C3%A9tricas-valida%C3%A7%C3%A3o-cruzada-bias-e-vari%C3%A2ncia-380513d97c95>