

EfficientEnsemble: Diagnóstico de câncer de mama em imagens de ultrassom utilizando processamento de imagens e *Ensemble de EfficientNets*

João O. B. Diniz^{1,4}, Domingos A. Dias Jr², Luana B. da Cruz²,
Ricardo C. S. Marques⁴, Daniel L. Gomes Jr¹, Omar A. C. Cortês¹,
Antônio O. de Carvalho Filho³, Darlan B. P. Quintanilha⁴

¹Fábrica de Inovação – Instituto Federal Do Maranhão (IFMA)
Maranhão – Brazil

²Universidade Federal de Cariri (UFCA)
Juazeiro do Norte – CE – Brasil

³Universidade Federal do Piauí (UFPI)
Picos – PI – Brasil

⁴Universidade Federal do Maranhão (UFMA)
São Luís – MA – Brasil

joao.bandeira@ifma.edu.br

Abstract. *Breast cancer diagnostic through ultrasound is challenging due to image complexity and variation in characteristics. The aim of this work is to propose a method that combines preprocessing, balanced data augmentation, and an Ensemble of EfficientNet to enhance diagnostic accuracy. The results show robust validation metrics, achieving an accuracy of 96.67%, specificity of 97.67%, sensitivity of 94.12%, F1-score of 94.96%, and AUC-ROC of 0.95896. The proposed approach could be a valuable tool to aid in breast cancer diagnosis from ultrasound images, potentially enhancing treatment efficiency and improving clinical outcomes.*

Resumo. *O diagnóstico de câncer de mama por meio de ultrassom é desafiador devido à complexidade das imagens e à variação nas características. O objetivo deste trabalho é propor um método que combina pré-processamento, aumento de dados balanceados e um Ensemble de EfficientNet para melhorar a precisão do diagnóstico. Os resultados mostram métricas de validação robustas, alcançando uma acurácia de 96,67%, uma especificidade de 97,67%, uma sensibilidade de 94,12%, um F1-score de 94,96%, e uma AUC-ROC de 0,95896. A abordagem proposta pode ser uma ferramenta valiosa para auxiliar no diagnóstico de câncer de mama em imagens de ultrassom, potencialmente aumentando a eficiência do tratamento e melhorando os resultados clínicos.*

1. Introdução

O câncer de mama é uma das principais causas de mortalidade entre as mulheres globalmente. De acordo com a Organização Mundial da Saúde (OMS), aproximadamente 15%

das mortes anuais são causadas por essa patologia [Cheng et al. 2010]. Uma detecção precoce é crucial para o tratamento adequado e, conseqüentemente, reduzir a taxa de mortalidade. A ultrassonografia (US) é um dos procedimentos seguros tanto para detecção quanto para o diagnóstico do câncer de mama, pois é não invasiva, não radioativa e fornece imagens de alta resolução em tempo real [Chougrad et al. 2018].

Todavia, para interpretar as imagens de US são necessários radiologistas treinados e experientes. Mesmo um especialista bem treinado pode apresentar uma taxa de variação interobservador no diagnóstico de tumores [Shan et al. 2016]. Os sistemas de detecção e diagnóstico auxiliado por computador (CAD/CADx) surgem como uma solução promissora para auxiliar nesses desafios. Esses sistemas podem automatizar a análise das imagens de US, auxiliando os profissionais de saúde na classificação de lesões mamárias [Moon et al. 2020].

Destaca-se ainda, que o uso de métodos de aprendizado profundo, como redes neurais convolucionais (CNNs), tem se destacado como uma abordagem eficaz em uma variedade de aplicações de visão computacional na área médica [Diniz et al. 2022b, Figueredo et al. 2023, Diniz et al. 2023, Matos et al. 2023]. Esses modelos têm a capacidade de aprender padrões diretamente das imagens, sem a necessidade de uma extração manual de características [Diniz et al. 2018]. Porém, destaca-se que a imagem de US é complexa e muitas vezes requer um pré-processamento adequado para destacar as estruturas suspeitas, a fim de obter resultados precisos.

Dado esta problemática, o objetivo principal deste trabalho é desenvolver e avaliar um método de diagnóstico automático de lesões mamárias em imagens de US utilizando técnicas de melhoramento de imagem e aprendizado profundo. O método proposto alcança as seguintes contribuições:

- Um método automático para diagnóstico que propõe pela primeira vez o uso de filtro guiado [He et al. 2012] para melhoramento das imagens de US de mama;
- O desenvolvimento de uma técnica de *Ensemble* de EfficientNets, também proposto pela primeira vez na literatura, que supera os resultados anteriormente alcançados em US de câncer de mama.

2. Revisão da Literatura

Nesta seção, são apresentados trabalhos relacionados ao método.

[Cao et al. 2020] destaca o problema de treinar modelos de aprendizado profundo quando há falta de amostras de treinamento em US de mama. Os autores propuseram uma abordagem chamada *noise filter network (NF-Net)*, cujos resultados mostraram uma precisão de 73%, sensibilidade de 80% e F1-score de 74%. Ainda, destacam que esses resultados indicam uma proposta promissora na classificação de lesões mamárias. Em [Moon et al. 2020], a classificação de lesões de mama em US utiliza fusão de imagens e diferentes arquiteturas de CNN, como VGGNet, ResNet e DenseNet. Os resultados foram acurácia de 94,62%, sensibilidade de 92,31%, especificidade de 95,60%, precisão de 90%, F1-score de 91,14% e área sob a curva (AUC) de 0,9711 na base de dados BUSI.

No método proposto por [Pang et al. 2021], foi utilizada uma técnica baseada em Radiomics com um modelo de rede neural adversária semi-supervisionado para aumento dos dados. A base de dados utilizada era privada, com 1.447 imagens de US,

sendo 767 benignas e 680 malignas. Os melhores resultados encontrados pelos autores foram uma acurácia de 90,41%, sensibilidade de 87,94% e especificidade de 85,86%. [Zhuang et al. 2021] propuseram a utilização do filtro bilateral. Em seguida, várias arquiteturas de CNN foram testadas para definir o modelo de treinamento. O trabalho apresentou acurácia de 95,48%, sensibilidade de 93,92%, especificidade de 98,33%, precisão de 98,11%, F1-score de 95,71% e AUC de 98,83%.

[Eroğlu et al. 2021] apresentam um método baseado em uma estrutura híbrida com três CNN para extração de características. Em seguida, utilizaram o algoritmo de *Minimum Redundancy Maximum Relevance* para selecionar as melhores e treinar uma máquina de vetor de suporte (SVM), apresentando resultado de acurácia de 95,6%. [Sirjani et al. 2023] teve como objetivo desenvolver uma arquitetura baseada na InceptionV3. Os autores utilizaram cinco bases de dados em conjunto para superar o problema da falta de dados. O modelo alcançou uma acurácia de 81%, sensibilidade de 77%, F1-score de 80% e AUC de 0,81. Por fim, [Kılıçarslan et al. 2023] propuseram o treinamento de três arquiteturas de ResNet combinadas para extração de características. Em seguida, usaram três técnicas diferentes para seleção das melhores características e o treinamento foi realizado por uma SVM. Em uma base de dados de 1.236 imagens, os melhores resultados apresentaram 84,9% de acurácia.

Poucos trabalhos abordam o uso de técnicas de processamento de imagens para aprimorar a classificação de câncer de mama em US, com a maioria preferindo arquiteturas de CNNs. Alguns combinam múltiplas redes para extração e classificação de características das lesões. O desafio dos dados limitados na US demanda atenção na preparação dos dados, incluindo o uso de aumento de dados. Diante dessas limitações, propõe-se um método que utiliza um algoritmo de filtro guiado [He et al. 2012] para melhorar a qualidade dos dados, uma técnica de aumento de dados balanceada para equilibrar amostras da classe minoritária no treinamento do modelo e uma técnica de *Ensemble* de EfficientNets para melhorar o desempenho da classificação. Essas abordagens visam superar as limitações propostas na literatura e trazer um método completamente automático que auxilie médicos especialistas no diagnóstico de câncer de mama.

3. Materiais e Método

Nesta seção, é descrito o método proposto. Basicamente, o método é composto por cinco etapas, conforme ilustrado na Figura 1. Em seguida, cada etapa é explicada.

3.1. Aquisição de Imagens

A base de dados utilizada para o método proposto foi a *Breast Ultrasound Images Dataset* (BUSI). Os dados foram coletados em 2018 e incluem imagens de US de mulheres entre 25 e 75 anos. O conjunto de dados consiste em 780 imagens com um tamanho médio de imagem de 500×500 pixels no formato PNG. Além disso, cada imagem é acompanhada pelo arquivo de marcação da lesão. As imagens são categorizadas em três classes: normal, benigna e maligna [Al-Dhabyani et al. 2020]. Neste trabalho, optou-se por utilizar apenas as imagens das classes benigna e maligna (210 e 454 imagens, respectivamente). Isso se justifica pelo fato de que o procedimento de biópsia é necessário apenas quando há dúvida no diagnóstico entre benignidade e malignidade. Como pacientes normais não apresentam essa incerteza, as imagens dessa classe não foram incluídas no conjunto de dados para

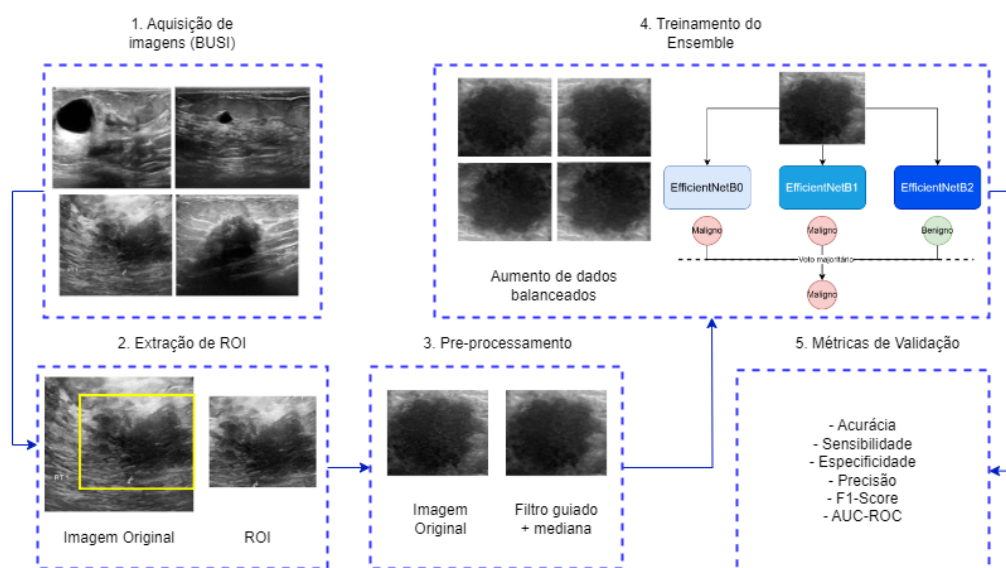


Figura 1. Ilustração do método proposto.

focar no problema de diagnóstico (lesões benignas e malignas) que é o objetivo principal deste estudo. A Figura 2 apresenta exemplos de cada classe.




Figura 2. Aquisição de imagens: (A) US benigna; (B) US maligna.

Na próxima etapa, será descrito a extração da região de interesse (ROI) que foi utilizada para melhorar o modelo, excluindo informações desnecessárias das imagens.

3.2. Extração da ROI

Como descrito anteriormente, as imagens contêm marcações realizadas por especialistas. Também, percebe-se, conforme ilustrado na Figura 2, que há uma quantidade significativa de informações na imagem que não são essenciais para a classificação e podem até mesmo confundir o classificador. Por isso, após realizar experimentos detalhados (discutidos na Seção 4), optou-se por extrair a ROI da lesão. Na prática, isso envolve a seleção da maior caixa delimitadora da lesão nas marcações e o recorte correspondente na imagem original, gerando assim uma nova imagem que será utilizada nas etapas seguintes do método. O procedimento de extração da ROI é ilustrado na Figura 3.

Com as ROIs extraídas, o próximo passo é o pré-processamento das imagens.

3.3. Pré-processamento

Muitos trabalhos mostram que o melhoramento de imagem para CNN, melhoraram os resultados da rede [Diniz et al. 2020, Júnior et al. 2021, Diniz et al. 2022a, Santos et al. 2023]. Nesta etapa, são aplicados dois filtros em sequência para aprimorar a representação da imagem. O primeiro é o filtro guiado [He et al. 2012], seguido




Figura 3. Extração da ROI: (A) Imagem original; (B) Marcação com caixa delimitadora em amarelo; (C) Imagem resultante.

pelo filtro da mediana [Gonzalez and Woods 2008]. A escolha do filtro guiado se dá pelo fato de que ele preserva as bordas da imagem, enquanto suaviza regiões homogêneas, o que é particularmente útil em US, já que as bordas são fatores críticos e determinantes para a interpretação de lesões benignas e malignas. O filtro da mediana é responsável por remover ruídos impulsivos na imagem que, embora o filtro guiado seja útil para preservar as bordas e suavizar regiões homogêneas, ele pode não ser tão eficaz na remoção de ruídos. A Figura 4 apresenta a aplicação desses filtros.




Figura 4. Pré-processamento: (A) Imagem da ROI; (B) Imagem Pré-processada.

Pode-se observar que os ruídos foram suavizados enquanto as bordas da lesão foram preservadas e realçadas. Este processo se mostrou eficaz para melhorar o resultado no treinamento da arquitetura de CNN.

3.4. Treinamento do *Ensemble*

Antes do treinamento do modelo, é preciso preparar os dados com o redimensionamento e o aumento de dados da classe minoritária no conjunto de dados de treinamento.

3.4.1. Preparação dos Dados

Primeiramente, é importante ressaltar que, após a etapa de extração da ROI, as dimensões das imagens na base de dados podem variar em altura e largura. No entanto, para otimizar o treinamento de arquiteturas CNN específicas, é necessário que todas as imagens tenham o mesmo tamanho em altura e largura. Por essa razão, optou-se por redimensionar todas as imagens para as dimensões de 224×224 , que são adequadas para o treinamento dentro do pipeline de aprendizado profundo [Júnior et al. 2021].

Em seguida, ao observar o total de 210 imagens malignas e 454 imagens benignas, torna-se evidente um problema de desbalanceamento entre as classes. Assim, a base de dados é dividida em três conjuntos: treinamento, validação e teste. Durante o treinamento, é realizado um aumento de dados com base na classe minoritária (imagens malignas) para equilibrar o número de amostras entre as classes.

Basicamente, tem-se a classe minoritária, o tamanho dela e o tamanho da classe majoritária. Então é definido uma série de hiperparâmetros para aumento de dados (intervalo de rotação até 5 graus, zoom de 10% na imagem, espelhamento horizontal e vertical). Assim, enquanto o tamanho da classe minoritária for menor que a da majoritária, essas transformações podem ocorrer até que seja alcançado o tamanho da classe majoritária. Como resultado temos o aumentado os dados e sua representatividade.

Após o equilíbrio das amostras de treinamento, define-se a arquitetura do *Ensemble* e procede-se com o treinamento do modelo.

3.4.2. *Ensemble de EfficientNets*

As arquiteturas EfficientNet são notáveis por sua eficiência computacional e desempenho superior em comparação com outras arquiteturas de CNNs. O diferencial das EfficientNets está no conceito de escalonamento composto, que envolve aumentar simultaneamente a largura, a profundidade e a resolução da rede. Essa abordagem é inovadora, pois difere da prática convencional de aumentar uma dimensão por vez, como é comum em outras arquiteturas [Tan and Le 2019].

Além disso, as EfficientNets foram projetadas para serem mais robustas ao *overfitting* devido à regularização incorporada em sua arquitetura. Graças ao conceito de escalonamento composto, essas redes conseguem lidar efetivamente com imagens de diferentes resoluções. A família de arquiteturas varia de B0 a B7 em termos de tamanho e poder computacional [Tan and Le 2019]. No entanto, cada arquitetura da família foi construída de maneira única e treinada em escalas diferentes, o que implica que cada modelo pode ter aprendido características distintas dos dados de entrada. Levando isso em consideração, uma abordagem de *Ensemble* baseada em votação é sugerida.

Um *Ensemble* de votação é uma técnica de aprendizado de máquina amplamente utilizada, que combina as previsões de vários modelos individuais para chegar a uma previsão final [Alpaydin 2020]. Essa técnica é comumente empregada em problemas de classificação, nos quais cada modelo individual é treinado de forma independente em um conjunto de dados e faz previsões sobre novos exemplos. O resultado final é determinado pela votação majoritária dos modelos componentes. Por exemplo, se três modelos forem treinados e dois deles predisserem que uma determinada imagem pertence à classe maligna, então ela será classificada como maligna. A Figura 5 ilustra esse processo.

No método proposto, foi treinado individualmente três arquiteturas individuais da família da EfficientNet (B0, B1 e B2), em seguida, é feito as previsões baseado em votação.

3.5. Métricas de Validação

Ao término do treinamento, as previsões baseadas em votação são avaliadas por meio de métricas de validação para determinar a eficácia do método proposto. Neste trabalho, foram utilizadas as métricas de Acurácia, Sensibilidade, Especificidade, Precisão, *F1-score* e a Área sob a curva ROC (AUC-ROC).




Figura 5. Ensemble de EfficientNets: (A) Imagem de entrada; (B) Predição por modelo; (C) Predição final.

4. Resultados e Discussão

Nesta seção, serão descritos os experimentos para definição das etapas do método apresentado na Seção 3. Ainda, serão discutidos os trabalhos relacionados e estudos de casos.

Para desenvolvimento do método e dos experimentos, foi utilizado um computador com as seguintes especificações: CPU Intel® Core™ i7 CPU@ 2.90GHz, GPU Nvidia RTX-3060 12GB, 16GB de memória RAM e Sistema Operacional Windows 11 Pro. Ainda, foi implementado em linguagem Python, com uso de bibliotecas como Pandas, OpenCV, Skicit-Learn e Keras.

4.1. Resultados Experimentais do Método

Para definir e validar cada etapa do método, foram realizados testes cada técnica.

Visando avaliar cada etapa e considerando o custo de treinamento das três arquiteturas, optou-se por executar cada etapa usando apenas a EfficientNetB0, buscando determinar as melhores técnicas para cada estágio. A arquitetura segue os padrões disponíveis na biblioteca Keras, com os seguintes hiperparâmetros: otimizador Adam com taxa de aprendizado de 0.001, um tamanho de lote (*batch size*) de 32 e 50 épocas de treinamento.

Os dados foram divididos em conjuntos de treinamento (60%), validação (20%) e teste (20%). Os conjuntos de treinamento e validação foram usados para criar o melhor modelo, enquanto o conjunto de teste foi utilizado para validação deste. As seções seguintes apresentam a comparação de cada etapa com e sem o uso da técnica escolhida.

4.1.1. Experimento com e sem Extração da ROI

Nesta etapa, para validar o impacto da extração da ROI, foram realizados experimentos com duas configurações: uma usando a imagem original sem pré-processamento e sem aumento de dados balanceados com a EfficientNetB0, e outra usando a extração da ROI também sem pré-processamento e sem aumento de dados balanceados, mas com a mesma arquitetura. Os resultados estão resumidos na Tabela 1.

Observa-se uma melhoria significativa em todas as métricas ao utilizar a extração das ROI. Esses resultados sugerem que a utilização da imagem original possivelmente

Tabela 1. Resultado da extração de ROI.

Experimento	Acurácia	Especificidade	Sensibilidade	Precisão	F1-score	AUC-ROC
Imagem original + EfficientNetB0	86,57%	89,36%	80,01%	76,19%	78,05%	0,8468
ROI + EfficientNetB0	89,55%	91,49%	85,33%	80,93%	82,93%	0,8824

continha informações que confundiam o classificador, prejudicando sua capacidade de generalização.

4.1.2. Experimento com e sem Pré-processamento

Agora, com a extração de ROI definida, o próximo passo é avaliar o impacto do pré-processamento. A Tabela 2 apresenta os resultados obtidos nesta etapa.

Tabela 2. Resultado do pré-processamento.

Experimento	Acurácia	Especificidade	Sensibilidade	Precisão	F1-score	AUC-ROC
Extração da ROI	89,55%	91,49%	85,33%	80,93%	82,93%	0,8824
ROI + Pré-processamento	91,04%	96,67%	85,03%	85,93%	85,96%	0,8931

Destaca-se que o uso dos filtros guiado, que realça as bordas, e da mediana, que trata os ruídos, resultou em uma melhora expressiva dos resultados. Notavelmente, a precisão aumentou 5%, evidenciando que o pré-processamento proposto desempenha um papel crucial no método.

4.1.3. Experimento com e sem Aumento de Dados Balanceados

Na etapa de preparação dos dados, é proposto o uso de um aumento de dados balanceados para auxiliar o treinamento. A fim de validar essa técnica proposta, foram conduzidos experimentos com e sem essa etapa. Os resultados são apresentados na Tabela 3.

Tabela 3. Resultado do aumento de dados balanceados.

Experimento	Acurácia	Especificidade	Sensibilidade	Precisão	F1-score	AUC-ROC
Sem aumento de dados	91,04%	96,67%	85,03%	85,93%	85,96%	0,8931
Com aumento de dados	92,76%	95,77%	91,33%	91,96%	91,96%	0,9037

Como é possível observar, o uso do aumento de dados foi crucial para melhorar os resultados, resultando em uma melhora nas métricas de sensibilidade, precisão e, consequentemente, no F1-score. Isso demonstra que ao empregar o aumento de dados, há um equilíbrio entre as classes de treinamento, o que leva a uma melhoria nas métricas de acerto dos verdadeiros positivos. Essa melhoria é refletida nas métricas mencionadas.

4.1.4. Experimento com EfficientNetB0 e Ensemble

Por fim, realizou-se a validação da escolha do *Ensemble* em vez do uso apenas de uma EfficientNet. A Tabela 4 apresenta um resumo de todos os resultados com todas as etapas e o método completo.

Tabela 4. Resultado do método completo (ROI - Extração de ROI, PP - Pré-processamento, AD - Aumento de Dados, ENB0 - EfficientNetB0.

Experimento	Acurácia	Especificidade	Sensibilidade	Precisão	F1-score	AUC-ROC
Imagem original + ENB0	86,57%	89,36%	80,01%	76,19%	78,05%	0,8468
ROI + ENB0	89,55%	91,49%	85,33%	80,93%	82,93%	0,8824
ROI + PP + ENB0	91,04%	96,67%	85,03%	85,93%	85,96%	0,8931
ROI + PP + AD + ENB0	92,76%	95,77%	89,33%	89,96%	89,96%	0,9037
ROI + PP + AD + Ensemble	96,67%	97,67%	94,12%	94,96%	94,96%	0,95896

Observa-se cada etapa incorporada resultou em melhorias nas métricas. O emprego do *Ensemble* demonstrou um aumento aproximadamente de 5% na acurácia e no F1-score, destacando a importância da combinação dos modelos na construção de um método robusto. É relevante ressaltar que, após a utilização do *Ensemble*, todas as métricas ultrapassaram os 94%, alcançando uma acurácia de 96,67%, especificidade de 97,67%, sensibilidade de 94,12%, F1-score de 94,96% e AUC-ROC de 0,95896.

Acredita-se que a combinação das técnicas empregadas e o modelo constituem uma ferramenta para o suporte ao diagnóstico de câncer de mama em imagens de US. Tal ferramenta pode auxiliar os especialistas na tomada de decisão, evitando procedimentos desnecessários e contribuindo para o aumento da cura e da sobrevivência dos pacientes.

4.2. Comparação com a Literatura

Conforme mencionado na Seção 2, vários estudos abordam o diagnóstico por meio de US. Um resumo juntamente com as técnicas usadas, é apresentado na Tabela 5.

Tabela 5. Comparação com os trabalhos relacionados.

Trabalho	Técnica	Acurácia	Especificidade	Sensibilidade	Precisão	F1-score	AUC-ROC
[Cao et al. 2020]	NF-Net	73,00%	-	80,00%	74,00%	-	-
[Moon et al. 2020]	Fusão de imagens + CNN	94,62%	95,60%	92,31%	90,00%	91,14%	0,9711
[Pang et al. 2021]	Radiomics + GAN	90,41%	-	87,94%	-	-	-
[Zhuang et al. 2021]	Filtro bilateral + CNN	95,48%	98,33%	93,92%	98,11%	95,71%	0,9883
[Eroğlu et al. 2021]	3 CNN + SVM	95,60%	-	-	-	-	-
[Sirjani et al. 2023]	InceptionV3	81,00%	-	77,00%	-	80,00%	0,8100
Método Proposto	ROI + PP + AD + Ensemble	96,67%	97,67%	94,12%	94,96%	94,96%	0,95896

Diversos estudos recentes sobre a classificação de câncer de mama em US enfocam o uso de CNN. Por exemplo, [Cao et al. 2020] introduziu a abordagem NF-Net para a classificação de lesões mamárias, alcançando 73% de precisão, 80% de sensibilidade e 74% de F1-score. [Moon et al. 2020] empregou fusão de imagens e diferentes CNNs (VGGNet, ResNet e DenseNet), obtendo 94,62% de acurácia, 92,31% de sensibilidade e 95,60% de especificidade na base BUSI. [Pang et al. 2021] usou Radiomics com uma rede neural adversária semi-supervisionada, conseguindo 90,41% de acurácia, 87,94% de sensibilidade e 85,86% de especificidade em uma base privada. Em outro estudo, [Zhuang et al. 2021] propôs um método com filtro bilateral e várias CNNs, alcançando 95,48% de acurácia, 93,92% de sensibilidade e 98,33% de especificidade. Por fim, [Kılıçarslan et al. 2023] combinou três arquiteturas ResNet com uma SVM, resultando em 84,9% de acurácia.

Diante desse cenário, o método proposto neste estudo aborda as deficiências encontradas na literatura, incorporando técnicas inovadoras. Isso inclui o uso de um filtro

guiado para o aprimoramento das imagens, uma estratégia não utilizada anteriormente em US, além de um aumento de dados balanceado e a implementação de um *Ensemble* de EfficientNets. Como resultado, o método alcançou uma acurácia de 96,67%, especificidade de 97,67%, sensibilidade de 94,12%, F1-score de 94,96% e AUC-ROC de 0,95896. Ao observar a acurácia e a sensibilidade como medidas principais para o diagnóstico correto do câncer de mama em US, o método alcançou o melhor resultado, superando os encontrados na literatura. Com isso, acredita-se que essa abordagem represente um avanço significativo na área e, aliada à expertise médica, pode se tornar uma ferramenta crucial para o diagnóstico, tratamento e cura do câncer de mama.

4.3. Estudo de Caso

Nesta seção, são apresentados dois estudos de caso. O primeiro envolve uma lesão da classe benigna, mas erroneamente classificada como câncer (Figura 6 (A)), enquanto o segundo é uma lesão maligna classificada erroneamente como benigna (Figura 6 (B)).




Figura 6. Estudo de caso. (A) Lesão benigna, classificada como maligna pelo método, (B) Lesão maligna, classificada como benigna pelo método.

Ao analisar o exemplo da Figura 6 (A), observa-se que, apesar de ser uma lesão benigna, suas bordas são irregulares, o que pode ter levado o modelo a classificá-la erroneamente como maligna. Por outro lado, na Figura 6 (B), as bordas são mais uniformes, resultando na classificação incorreta da lesão como benigna. Apesar dos erros de classificação, considera-se que o modelo ainda é robusto e, quando combinado com a expertise médica, pode desempenhar um papel crucial no combate ao câncer de mama.

5. Conclusão

O método proposto combina pré-processamento, aumento de dados balanceados e um Ensemble de EfficientNet para melhorar a precisão no diagnóstico de câncer de mama por meio de imagens de US. Os resultados robustos e consistentes alcançados demonstram a eficácia do método em lidar com a complexidade e variação das características das lesões, sendo pioneiro no uso dessas técnicas.

Para futuras pesquisas, sugere-se explorar e comparar diferentes filtros de aprimoramento de imagem, buscando a combinações eficazes. Além disso, investigar outras abordagens de *Ensemble*, e inserção de mais CNNs. Por último, uma análise de otimização dos hiperparâmetros pode levar a resultados ainda mais promissores, aprimorando ainda mais a eficácia do método proposto.

6. Agradecimentos

Agradecemos ao apoio do Ministério da Ciência, Tecnologia e Inovação (MCTI) por meio dos recursos da Lei nº 8.248, de 23 de outubro de 1991, no âmbito do PPI Softex, coordenado pela Associação para Promoção da Excelência do Software Brasileiro (Softex),

e publicado como Residência TIC09 (processo 01245.005714/2022-18), realizado pelo Instituto Federal do Maranhão (IFMA).

Referências

- Al-Dhabyani, W., Gomaa, M., Khaled, H., and Fahmy, A. (2020). Dataset of breast ultrasound images. *Data in brief*, 28:104863.
- Alpaydin, E. (2020). *Introduction to machine learning*. MIT press.
- Cao, Z., Yang, G., Chen, Q., Chen, X., and Lv, F. (2020). Breast tumor classification through learning from noisy labeled ultrasound images. *Medical Physics*, 47(3):1048–1057.
- Cheng, H.-D., Shan, J., Ju, W., Guo, Y., and Zhang, L. (2010). Automated breast cancer detection and classification using ultrasound images: A survey. *Pattern recognition*, 43(1):299–317.
- Chougrad, H., Zouaki, H., and Alheyane, O. (2018). Deep convolutional neural networks for breast cancer screening. *Computer methods and programs in biomedicine*, 157:19–30.
- Diniz, J., Quintanilha, D., Filho, A. C., Jr, D. G., Silva, A., Jr, G. B., Paiva, A., and Luz, D. (2023). Detecção de covid-19 em imagens de raio-x de tórax através de seleção automática de pré-processamento e de rede neural convolucional. In *Anais do XXIII Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 162–173, Porto Alegre, RS, Brasil. SBC.
- Diniz, J. O. B., Diniz, P. H. B., Valente, T. L. A., Silva, A. C., de Paiva, A. C., and Gattass, M. (2018). Detection of mass regions in mammograms by bilateral analysis adapted to breast density using similarity indexes and convolutional neural networks. *Computer methods and programs in biomedicine*, 156:191–207.
- Diniz, J. O. B., Ferreira, J. L., Cortes, O. A. C., Silva, A. C., and de Paiva, A. C. (2022a). An automatic approach for heart segmentation in ct scans through image processing techniques and concat-u-net. *Expert Systems with Applications*, 196:116632.
- Diniz, J. O. B., Ferreira, J. L., Diniz, P. H. B., Silva, A. C., and de Paiva, A. C. (2020). Esophagus segmentation from planning ct images using an atlas-based deep learning approach. *Computer Methods and Programs in Biomedicine*, 197:105685.
- Diniz, J. O. B., Ferreira, J. L., Diniz, P. H. B., Silva, A. C., and Paiva, A. C. (2022b). A deep learning method with residual blocks for automatic spinal cord segmentation in planning ct. *Biomedical signal processing and control*, 71:103074.
- Eroğlu, Y., Yildirim, M., and Çinar, A. (2021). Convolutional neural networks based classification of breast ultrasonography images by hybrid method with respect to benign, malignant, and normal using mrmr. *Computers in biology and medicine*, 133:104407.
- Figueredo, W., Silva, I., Diniz, J., Silva, A., Paiva, A., Salomão, A., and Oliveira, M. (2023). Abordagem computacional baseada em deep learning para o diagnóstico de endometriose profunda através de imagens de ressonância magnética. In *Anais do XXIII Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 138–149, Porto Alegre, RS, Brasil. SBC.

- Gonzalez, R. and Woods, R. (2008). *Digital image processing*. Pearson, Prentice Hall.
- He, K., Sun, J., and Tang, X. (2012). Guided image filtering. *IEEE transactions on pattern analysis and machine intelligence*, 35(6):1397–1409.
- Júnior, D. A. D., da Cruz, L. B., Diniz, J. O. B., da Silva, G. L. F., Junior, G. B., Silva, A. C., de Paiva, A. C., Nunes, R. A., and Gattass, M. (2021). Automatic method for classifying covid-19 patients based on chest x-ray images, using deep features and pso-optimized xgboost. *Expert Systems with Applications*, 183:115452.
- Júnior, D. D., Cruz, L., Diniz, J., Júnior, G. B., and Silva, A. (2021). Classificação automática de glóbulos brancos usando descritores de forma e textura e extreme gradient boosting. In *Anais do XXI Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 95–106, Porto Alegre, RS, Brasil. SBC.
- Kılıçarslan, G., Koç, C., Özyurt, F., and Gül, Y. (2023). Breast lesion classification using features fusion and selection of ensemble resnet method. *International Journal of Imaging Systems and Technology*, 33(5):1779–1795.
- Matos, C., Oliveira, M., Diniz, J., Fernandes, A., Junior, G. B., and Paiva, A. (2023). Ppm-deeplab: Módulo de pirâmide de pooling como codificador da rede deeplabv3+ para segmentação de rins, cistos e tumores renais. In *Anais do XXIII Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 210–221, Porto Alegre, RS, Brasil. SBC.
- Moon, W. K., Lee, Y.-W., Ke, H.-H., Lee, S. H., Huang, C.-S., and Chang, R.-F. (2020). Computer-aided diagnosis of breast ultrasound images using ensemble learning from convolutional neural networks. *Computer methods and programs in biomedicine*, 190:105361.
- Pang, T., Wong, J. H. D., Ng, W. L., and Chan, C. S. (2021). Semi-supervised gan-based radiomics model for data augmentation in breast ultrasound mass classification. *Computer Methods and Programs in Biomedicine*, 203:106018.
- Santos, P., Brito, V., Filho, A. C., Sousa, A., Diniz, J., and Luz, D. (2023). Efficientbacillus: uma arquitetura profunda para detecção dos bacilos de koch. In *Anais do XXIII Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 198–209, Porto Alegre, RS, Brasil. SBC.
- Shan, J., Alam, S. K., Garra, B., Zhang, Y., and Ahmed, T. (2016). Computer-aided diagnosis for breast ultrasound using computerized bi-rads features and machine learning methods. *Ultrasound in medicine & biology*, 42(4):980–988.
- Sirjani, N., Oghli, M. G., Tarzarni, M. K., Gity, M., Shabanzadeh, A., Ghaderi, P., Shiri, I., Akhavan, A., Faraji, M., and Taghipour, M. (2023). A novel deep learning model for breast lesion classification using ultrasound images: A multicenter data evaluation. *Physica Medica*, 107:102560.
- Tan, M. and Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning*, page 6105. PMLR.
- Zhuang, Z., Yang, Z., Raj, A. N. J., Wei, C., Jin, P., and Zhuang, S. (2021). Breast ultrasound tumor image classification using image decomposition and fusion based on adaptive multi-model spatial feature fusion. *Computer methods and programs in biomedicine*, 208:106221.