



**UNIVERSIDADE ESTADUAL DO PIAUÍ – UESPI
CAMPUS ALEXANDRE ALVES DE OLIVEIRA
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**



JOSÉ FHILIPE MARTINS COELHO

PROCESSAMENTO

**DIGITAL DE IMAGENS APLICADO À MAMOGRAFIA: Uma
abordagem baseada em técnicas de segmentação, realce e marcação de
lesões**

**Parnaíba – Piauí
2025**

JOSÉ FHFILIPE MARTINS COELHO

PROCESSAMENTO

**DIGITAL DE IMAGENS APLICADO À MAMOGRAFIA: Uma
abordagem baseada em técnicas de segmentação, realce e marcação de
lesões**

Trabalho de Conclusão de Curso (artigo) apresentado ao Curso de Bacharelado em Ciência da Computação da Universidade Estadual do Piauí, Campus Alexandre Alves de Oliveira, como requisito parcial para obtenção do grau de bacharel em Ciência da Computação.

Orientador: Prof. Dr Dario Brito Calçada

**Parnaíba – Piauí
2025**

PROCESSAMENTO DIGITAL DE IMAGENS APLICADO À MAMOGRAFIA: Uma abordagem baseada em técnicas de segmentação, realce e marcação de lesões

José Filipe Martins Coelho¹, Dario Brito Calçada¹

¹ Curso de Ciência da Computação, Universidade Estadual do Piauí (UESPI) – Parnaíba, Piauí – Brasil

josefmc@aluno.uespi.br

Abstract. This study investigates the application of a digital image processing pipeline to optimize mammogram analysis, using the public INbreast dataset and a private clinical collection. The methodology comprises sequential steps, including automatic breast region cropping, intensity normalization via percentile truncation, and adaptive contrast enhancement using the CLAHE algorithm. Subsequently, morphological and contour-based criteria are applied to generate bounding boxes over regions of interest. The results show that while preprocessing techniques significantly improve the visual quality of images for medical interpretation or as input for computer-aided diagnosis (CAD) systems, the automatic detection stage exhibits limitations in cases of low contrast or lesions with complex morphology. The work concludes that the classical approach serves as a fundamental basis, but its robustness is limited, highlighting the need for integration with machine learning models for more accurate and generalizable detection.

Keywords. Mammography; Image Processing; CLAHE; Segmentation; Breast Lesions; Computer-Aided Diagnosis.

Resumo. Este estudo investiga a aplicação de um pipeline de processamento digital de imagens para otimizar a análise de mamografias, utilizando o dataset público INbreast e um acervo clínico privado. A metodologia abrange etapas sequenciais, incluindo recorte automático da região mamária, normalização de intensidade por truncamento de percentis e realce de contraste adaptativo com o algoritmo CLAHE. Subsequentemente, critérios morfológicos e de contorno são aplicados para gerar caixas delimitadoras (bounding boxes) sobre regiões de interesse. Os resultados demonstram que, embora as técnicas de pré-processamento melhorem significativamente a qualidade visual das imagens para interpretação médica ou como entrada para sistemas de diagnóstico assistido por computador (CAD), a etapa de detecção automática apresenta limitações em casos de baixo contraste ou lesões de morfologia complexa. O trabalho conclui que a abordagem clássica é uma base fundamental, mas sua robustez é limitada, evidenciando a necessidade de integração com modelos de aprendizado de máquina para uma detecção mais acurada e generalizável.

Palavras-Chave. Mamografia; Processamento de Imagem; CLAHE; Segmentação; Lesões Mamárias; Diagnóstico Assistido por Computador.

1. Introdução

O câncer de mama persiste como uma das principais causas de mortalidade oncológica entre mulheres em escala global. Nesse cenário, a mamografia se consolida como o método padrão-ouro para o rastreamento e diagnóstico precoce, permitindo a detecção de lesões em estágios iniciais e aumentando significativamente as taxas de sobrevida (Hussain et al., 2024). Contudo, a interpretação de exames mamográficos é uma tarefa

complexa, suscetível a desafios como a baixa densidade do tecido mamário, a presença de artefatos de imagem e a sutileza de certas lesões, como microcalcificações e massas de contornos irregulares (Gao et al., 2023).

A subjetividade inerente à análise visual e a variabilidade interobservador podem levar a diagnósticos falso-positivos ou falso-negativos, impactando o manejo clínico da paciente. Para mitigar tais desafios, o campo do Processamento Digital de Imagens (PDI) oferece um arsenal de técnicas para aprimorar a qualidade visual das mamografias e automatizar a identificação de áreas suspeitas (Habeeb; Vuksanovic; Al-Zaydi, 2023).

Este trabalho propõe e avalia um *pipeline* metodológico fundamentado em técnicas clássicas de PDI para o pré-processamento e análise de mamografias. A abordagem sequencial engloba: (1) segmentação e recorte automático da região mamária; (2) normalização da faixa dinâmica de intensidades de pixel; (3) realce de contraste local adaptativo com o algoritmo CLAHE; e (4) segmentação de regiões suspeitas com a geração de caixas delimitadoras (*bounding boxes*). O objetivo é estruturar uma base de processamento que prepare as imagens de forma otimizada, seja para a interpretação de um radiologista ou como etapa de entrada para sistemas de Diagnóstico Assistido por Computador (CAD) baseados em inteligência artificial.

2. Processamento de Imagens e Visão Computacional em Imagens Médicas

O Processamento Digital de Imagens é a disciplina que utiliza algoritmos computacionais para realizar operações em uma imagem digital com o objetivo de extrair informações ou aprimorá-la para uma finalidade específica. Em imagens médicas, seu papel é fundamental, envolvendo desde a remoção de ruídos até a segmentação de estruturas anatômicas. Técnicas como a equalização de histograma e a aplicação de filtros espaciais são amplamente utilizadas para melhorar a visualização de características de interesse (Srivastav et al., 2022).

A Visão Computacional, por sua vez, avança um passo além, buscando emular a capacidade humana de interpretação visual. Empregando algoritmos mais complexos, como as Redes Neurais Convolucionais (CNNs), a visão computacional permite o reconhecimento de padrões sofisticados, sendo a tecnologia central por trás dos modernos sistemas de detecção de câncer em imagens médicas (Habeeb et al., 2023). Este trabalho, no entanto, foca-se nas técnicas clássicas de PDI que servem como alicerce para essas abordagens avançadas.

O contraste em mamografias é um fator crítico, pois lesões podem se manifestar como alterações sutis na densidade do tecido. A Equalização de Histograma Adaptativa com Limite de Contraste (CLAHE) é uma técnica superior à equalização global, pois opera em pequenas regiões da imagem (tiles), calculando um histograma para cada uma. Isso permite realçar o contraste localmente sem amplificar excessivamente o ruído em regiões homogêneas, um problema comum em métodos globais. Conforme demonstrado por Srivastav et al. (2022), o CLAHE é particularmente eficaz para realçar microcalcificações e as bordas de massas mamárias.

A identificação de lesões frequentemente começa com a delimitação de suas fronteiras. A detecção de bordas é, portanto, uma etapa crucial. O algoritmo de *Canny* é reconhecido por sua robustez, superando métodos como Sobel e Prewitt por incorporar

um processo de supressão de não-máximos e um limiar com histerese. Essa abordagem de dois limiares permite detectar bordas fortes e, em seguida, conectar a elas bordas fracas, resultando em contornos mais contínuos e menos suscetíveis a ruído (Syahfitri et al., 2023). A eficácia do *Canny* na segmentação de mamografias foi validada em estudos como o de Srivastav et al. (2022).

3. Metodologia Aplicada ao Processamento de Mamografias

O fluxo de trabalho proposto foi implementado utilizando a linguagem de programação Python, com o suporte de bibliotecas consolidadas na comunidade científica. A biblioteca PyDICOM foi utilizada para a leitura e extração dos dados de pixel de arquivos no formato DICOM, padrão na imagiologia médica. A manipulação das imagens, aplicação de filtros, segmentação e operações morfológicas foram conduzidas pela biblioteca OpenCV (*Open Source Computer Vision Library*).

O estudo utilizou imagens do *dataset* público INbreast, uma base de dados de referência que contém mamografias com anotações de lesões validadas por especialistas. Para esta análise exploratória, foram selecionadas quatro imagens que representam diferentes níveis de desafio diagnóstico. O *pipeline* metodológico foi aplicado sequencialmente a cada imagem, conforme descrito nas subseções a seguir.

3.1. Recorte Automático da Região Mamária

Para isolar a região de interesse (o tecido mamário) e eliminar elementos irrelevantes como fundo, rótulos e artefatos, foi desenvolvido um processo de recorte automático.

1. Suavização: Um filtro de desfoque gaussiano é aplicado para atenuar ruídos de alta frequência, uma prática comum que melhora a eficácia dos passos subsequentes (Hasan et al., 2024).
2. Binarização: A imagem é convertida para uma máscara binária através de um limiar adaptativo, separando o tecido mamário (primeiro plano) do fundo.
3. Detecção de Contorno: O maior contorno fechado na máscara binária, correspondente à mama, é identificado.
4. Recorte: Uma caixa delimitadora (*bounding box*) mínima é calculada em torno deste contorno, e suas coordenadas são usadas para recortar a imagem original, focando a análise exclusivamente no tecido mamário.

3.2. Truncagem e Normalização de Intensidade

A fim de padronizar a faixa dinâmica das imagens e reduzir o impacto de pixels extremos (outliers), foi aplicada uma normalização estatística.

1. Truncagem por Percentil: Os valores de intensidade de pixel são truncados, descartando-se os 5% mais baixos e o 1% mais alto. Essa abordagem, também utilizada por Iskandar, Jeremy e Fathony (2022), preserva a maior parte da informação diagnóstica enquanto remove valores extremos que poderiam distorcer o contraste.
2. Normalização: Os valores de intensidade restantes são remapeados linearmente para o intervalo [0, 255], garantindo que todas as imagens processadas tenham uma escala de cinza consistente para as etapas seguintes.

3.3. Realce de Contraste com CLAHE

Com a imagem normalizada, o algoritmo CLAHE foi aplicado para realçar detalhes sutis. O algoritmo divide a imagem em uma grade de regiões e aplica a equalização de histograma a cada uma, limitando a amplificação do contraste para evitar a saturação de ruído. As regiões processadas são então recombinadas suavemente por meio de interpolação bilinear para evitar artefatos de bloco.

3.4. Segmentação de Massas e Geração de *Bounding Box*

A etapa final visa localizar potenciais lesões.

1. Filtragem Bilateral: Um filtro bilateral é aplicado para suavizar a imagem, preservando as bordas nítidas, que são cruciais para a detecção.
2. Detecção de Bordas com Canny: O algoritmo de *Canny* é utilizado para gerar um mapa de bordas da imagem processada.
3. Análise de Contornos: Os contornos fechados no mapa de bordas são identificados. Contornos com área inferior a um limiar pré-definido (100 pixels) são descartados para eliminar ruído e microrregiões irrelevantes.
4. Geração da Bounding Box: O maior contorno remanescente é selecionado como a região suspeita mais provável. Uma caixa delimitadora retangular é então desenhada ao redor deste contorno, conforme abordagem similar à de Eetveldt (2023), para fornecer uma marcação visual clara da localização da potencial lesão.

3.5. Técnicas de Pré-Processamento Aplicada às Imagens

3.5.1. Recorte Automático da Região da Mama

Para eliminar partes não relevantes da imagem (como o fundo preto, textos, marcações e rótulos), foi implementado um processo de segmentação morfológica com recorte automático da região mamária. Inicialmente, aplicou-se um desfoque Gaussiano à imagem normalizada para suavizar o ruído de alta frequência seguindo abordagens semelhantes às propostas por Hasan et al. (2024), que demonstraram a eficácia dessa técnica em tarefas de pré-processamento de imagens. Em seguida, foi realizada uma limiarização adaptativa baseada na interpretação fotométrica da imagem (e.g., MONOCHROME2), convertendo a imagem em uma máscara binária. A equação da limiarização pode ser expressa como:

$$M(x, y) = \begin{cases} 1 & se I(x, y) \geq t; \\ 0 & caso contrário \end{cases}$$

onde t é um limiar adaptativo global ou determinado pelo método de Otsu. Após a binarização, aplicou-se detecção de contornos externos e selecionou-se o maior contorno (maior área), que corresponde à mama. Com base nesse contorno, calculou-se o retângulo envolvente mínimo (bounding box), usado para recortar a imagem e isolar a região anatômica de interesse, assim conseguindo o resultado mostrado nas figuras 1 e 2:

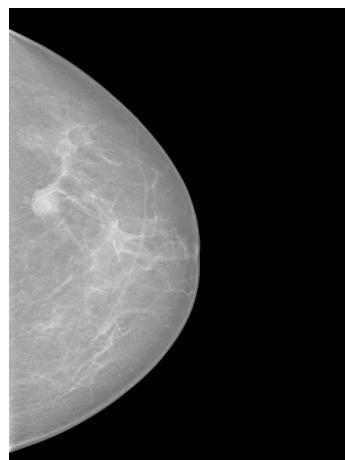


Figura 1. Mamografia sem alterações

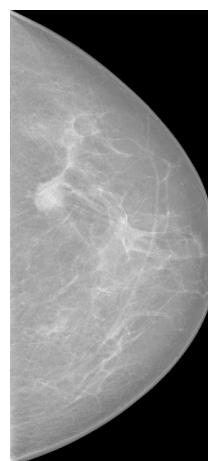


Figura 2. Mamografia com o corte

3.5.2. Truncagem e Normalização das Intensidades

A primeira etapa do pré-processamento tem como objetivo reduzir a influência de valores extremos de intensidade que podem surgir devido a artefatos, ruídos ou regiões de baixa relevância diagnóstica. Para isso, aplicou-se uma normalização por truncamento estatístico baseada em percentis, técnica também empregada em estudos recentes para pré-processamento de mamografias, visando melhorar a qualidade da imagem antes da classificação por redes neurais convolucionais (Iskandar; Jeremy; Fathony, 2022). Matematicamente, essa técnica é implementada pela função:

$$I_{trunc}(x, y) = \min\left(\max(I(x, y), P_5), P_{99}\right)$$

Onde $I(x, y)$ representa o valor de intensidade do pixel, e P_5 e P_{99} são os percentis 5 e 99 da distribuição dos pixels distintos de zero, foram escolhido esses valores pois assim é possível evitar que a imagem fique com muito ruído após a normalização. Essa operação descarta os valores abaixo de P_5 e acima de P_{99} , comprimindo a faixa dinâmica de intensidades úteis. Em seguida, a imagem truncada é normalizada para o intervalo $[0, 1]$ por meio da equação:

$$I_{norm}(x, y) = \frac{I_{trunc}(x, y) - P_5}{P_{99} - P_5}$$

Essa transformação permite padronizar a escala de intensidade das imagens, promovendo maior uniformidade na aplicação dos filtros subsequentes. Pixels originalmente iguais a zero (regiões fora da mama) são mantidos com valor zero, preservando o fundo da imagem, após a normalização é possível perceber que o maior contraste destaca bem as áreas da mama como mostrado nas figuras 3 e 4.

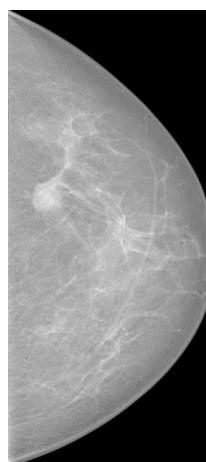


Figura 3. Mamografia sem a normalização

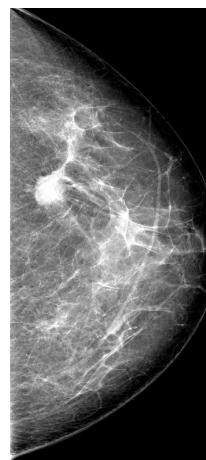


Figura 4. Mamografia com a normalização

3.5.3. Realce de Contraste com CLAHE

Após a normalização, aplicou-se o algoritmo CLAHE (Contrast Limited Adaptive Histogram Equalization) com o intuito de realçar estruturas sutis, como microcalcificações ou margens de massas pouco contrastadas (Srivastav et al., 2022). O CLAHE atua de forma local, operando em pequenas regiões (ou tiles) da imagem, aumentando o contraste de cada uma separadamente. A função de transformação utilizada pelo CLAHE é baseada na redistribuição do histograma acumulado (CDF). A transformação de cada intensidade r dentro de um tile é definida como:

$$T(r) = \left(\frac{N_{pixels} - N_{cdf,min}}{N_{cdf,max} - N_{cdf,min}} \right) \cdot (CDF(r) - N_{cdf,min}) \cdot (L - 1)$$

onde:

- $CDF(r)$ é a função de distribuição acumulada do histograma local,
- N_{pixels} é o número total de pixels no tile,
- L é o número de níveis de cinza (tipicamente 256),
- O clip limit define o valor máximo que uma frequência pode assumir, evitando amplificações de ruído.

Após o processamento local, as regiões são combinadas por interpolação bilinear, de modo a evitar descontinuidades visuais entre os blocos, com isso temos um realce maior nas áreas escuras dando mais destaque para as áreas claras, como mostrado nas figuras 5 e 6.

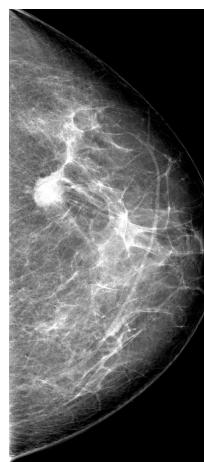


Figura 5. Mamografia sem o filtro CLAHE

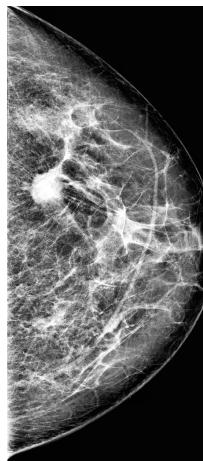


Figura 6. Mamografia com o filtro CLAHE

3.5.4. Segmentação de Massas

A próxima etapa consiste na segmentação de massas mamárias por meio da detecção de bordas e análise de contornos. Inicialmente, utilizou-se o filtro bilateral para preservar bordas enquanto suaviza regiões homogêneas. Após o pré-processamento, aplicou-se o algoritmo de *Canny* para detecção de bordas, definido matematicamente pela derivada do gradiente, conforme proposto por Nurul Azmi Syahfitri (2023):

$$G(x, y) = \sqrt{\left(\frac{\partial I}{\partial x}\right)^2 + \left(\frac{\partial I}{\partial y}\right)^2}$$

Onde o valor de G é comparado com dois limiares para detectar bordas fracas e fortes. Contornos fechados foram extraídos a partir da imagem binária resultante. Cada contorno foi avaliado segundo sua área por meio da integral discreta:

$$\text{Área}(C) = \sum_{i=0}^{n-1} \frac{x_i y_{i+1} - x_{i+1} y_i}{2}$$

Apenas contornos com área superior a 100 pixels foram mantidos, sendo desenhados em uma máscara binária final representando possíveis massas.

3.5.5. Geração e Desenho da Bounding Box

Com a máscara de regiões suspeitas definida, foi realizada a conversão da mesma para uma *bounding box* retangular. Para isso, extraiu-se o contorno da maior massa da imagem (maior área). Em seguida, foi utilizado o método de retângulo envolvente (`cv2.boundingRect`) para obter as coordenadas. Essa abordagem é semelhante à utilizada

por Eetveldt (2023), que converteu as máscaras de lesões do conjunto INbreast em *bounding boxes* retangulares para treinar um modelo YOLOv4:

$$BBox = [x_{min}, y_{min}, x_{max}, y_{max}]$$

Essas coordenadas delimitam o menor retângulo que engloba a massa segmentada. O retângulo é então desenhado sobre a imagem original com uma borda colorida (geralmente verde) para facilitar a visualização clínica ou computacional. Essa etapa final não realiza qualquer classificação da lesão, mas fornece uma localização espacial objetiva que pode ser utilizada por profissionais de saúde para análise direcionada ou por algoritmos de detecção mais complexos em etapas posteriores.

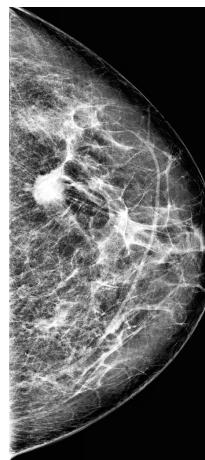


Figura 7. Mamografia sem a *bounding box*

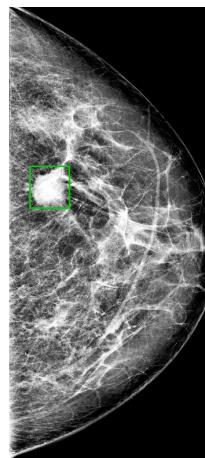


Figura 8. Mamografia com a *bounding box*

4. Resultados e Discussão

A aplicação das técnicas de pré-processamento e segmentação permitiu a identificação de possíveis regiões suspeitas em diversas mamografias. As etapas de truncagem, normalização, realce com CLAHE, recorte automático e geração de *bounding boxes* foram aplicadas uniformemente às imagens de diferentes pacientes. No entanto, os resultados obtidos mostraram variação significativa de desempenho entre os casos analisados.

Nas imagens em que as massas apresentam contraste acentuado e bordas bem definidas, como pode ser observado na figura 9:

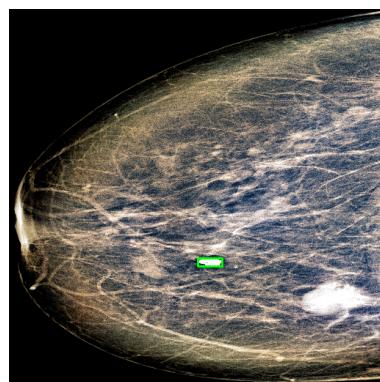


Figura 9. Mamografia com *bounding box* correta

A metodologia foi capaz de detectar a massa com relativa precisão, gerando uma *bounding box* compatível com a área de interesse. Isso indica que, sob condições ideais de contraste e textura, o algoritmo é funcional e pode auxiliar na marcação de possíveis lesões. Entretanto, na maioria das imagens — como nas figuras 10 e 11:

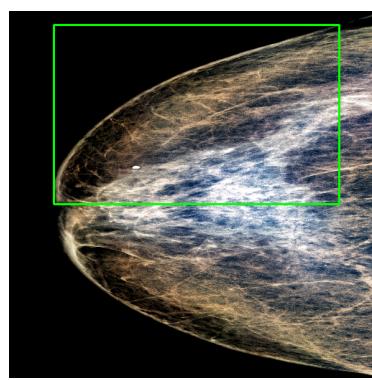


Figura 10. Mamografia com *bounding box* incorreta

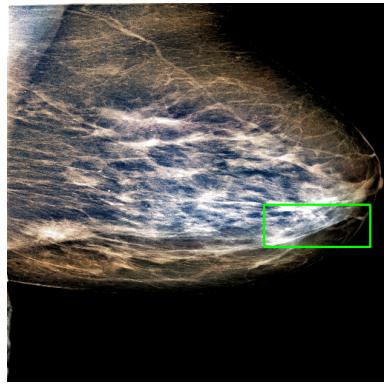


Figura 11. Outra mamografia com *bounding box* incorreta

A aplicação do *pipeline* metodológico produziu resultados variáveis, que destacam tanto o potencial quanto as limitações das técnicas clássicas de PDI.

Em casos onde as mamografias apresentavam lesões com bordas bem definidas e alto contraste em relação ao tecido circundante, a metodologia demonstrou eficácia. O algoritmo foi capaz de segmentar corretamente a região de interesse e gerar uma *bounding box* precisa sobre a massa, validando a funcionalidade do *pipeline* em condições ideais.

Entretanto, em cenários mais desafiadores, que representam uma parcela significativa dos casos clínicos, o método apresentou falhas. Em imagens com baixo contraste entre a lesão e o tecido denso, ou em casos de massas com margens espiculadas e formato irregular, a detecção de bordas com o algoritmo de *Canny* foi ineficaz. Isso resultou na geração de *bounding boxes* incorretas, que delimitavam regiões de tecido normal, ou na falha completa de detecção.

A análise desses resultados permite inferir as seguintes limitações:

- **Dependência de Contraste:** A abordagem baseada em detecção de bordas é intrinsecamente dependente de gradientes de intensidade acentuados, o que a torna frágil em lesões sutis.
- **Sensibilidade a Ruído e Textura:** A densidade e a textura do parênquima mamário podem gerar múltiplos contornos falsos, confundindo o algoritmo, que assume que o maior contorno é a lesão de interesse.
- **Falta de Contexto Semântico:** O método não possui capacidade de aprendizado ou compreensão semântica. Ele não distingue uma massa de uma sobreposição de tecido denso, tratando ambos como objetos a serem segmentados com base em propriedades de baixo nível (área, forma).

Essas falhas demonstram que, embora o pré-processamento (recorte, normalização e CLAHE) seja uma etapa valiosa e robusta para melhorar a qualidade da imagem, a etapa de detecção baseada apenas em critérios morfológicos não é suficientemente generalizável para aplicação clínica confiável em larga escala.

6. Considerações Finais

A realização deste trabalho possibilitou a demonstração da construção de um *pipeline* de processamento de imagens mamográficas utilizando técnicas clássicas. As etapas de

pré-processamento, especialmente o recorte automático e o realce com CLAHE, provaram ser eficazes na padronização e melhoria da qualidade visual das imagens, constituindo um passo fundamental para qualquer análise subsequente, seja ela humana ou computacional.

Contudo, a fase de detecção automática de lesões revelou as limitações inerentes a uma abordagem não supervisionada e baseada exclusivamente em regras morfológicas. A incapacidade do sistema de se adaptar à vasta variabilidade anatômica e patológica das mamografias reais limita seu uso como ferramenta de diagnóstico autônoma.

Os resultados reforçam a conclusão de que, para alcançar a robustez e a acurácia necessárias para o ambiente clínico, é imperativa a transição de métodos clássicos para abordagens de aprendizado supervisionado.

Para trabalhos futuros, recomenda-se:

- Integração com Aprendizado de Máquina: Utilizar o *pipeline* de pré-processamento desenvolvido como base para treinar um modelo de rede neural convolucional (CNN), como YOLO ou U-Net, em um *dataset* anotado como o INbreast. Isso permitiria que o sistema aprendesse a distinguir padrões complexos associados a lesões.
- Validação Quantitativa: Realizar uma avaliação rigorosa do desempenho do modelo utilizando métricas padrão como acurácia, sensibilidade, especificidade e a curva ROC (Receiver Operating Characteristic).
- Redução de Falsos Positivos: Implementar técnicas de pós-processamento ou desenvolver modelos de classificação secundários para analisar as regiões detectadas e reduzir a taxa de falsos positivos, aumentando a confiança clínica no sistema.

Com esses avanços, é possível evoluir da base metodológica aqui estabelecida para um sistema de auxílio ao diagnóstico mais preciso, confiável e clinicamente relevante.

Referências

EETVELDT, Jordan Van. End-to-end breast cancer detection in Python — Part 1. **TDS Archive**, 26 set. 2023. Disponível em: <<https://medium.com/data-science/end-to-end-breast-cancer-detection-in-python-part-1-13a1695d455>>. Acesso em: 23 jun. 2025

GAO, Ying'e *et al.* The application of traditional machine learning and deep learning techniques in mammography: a review. **Frontiers in Oncology**, v. 13, p. 1213045, 11 ago. 2023.

HABEEB, Zeyad Q.; VUKSANOVIC, Branislav; AL-ZAYDI, Imad Q. Breast Cancer Detection Using Image Processing and Machine Learning. **Journal of Image and Graphics**, v. 11, n. 1, p. 1–8, mar. 2023.

HASAN, Shagor *et al.* Image processing-based noise-resilient insulator defect detection using YOLOv8x. **IET Smart Grid**, v. 7, n. 6, p. 1036–1053, dez. 2024.

HUSSAIN, Sadam *et al.* Breast cancer risk prediction using machine learning: a systematic review. **Frontiers in Oncology**, v. 14, p. 1343627, 20 mar. 2024.

ISKANDAR, Aulia Arif; JEREMY, Michael; FATHONY, Muhammad. Breast Cancer Image Pre-Processing With Convolutional Neural Network For Detection and Classification. In: 2022 4TH INTERNATIONAL CONFERENCE ON BIOMEDICAL ENGINEERING (IBIOMED). **2022 4th International Conference on Biomedical Engineering (IBIOMED)**. out. 2022. Disponível em: <<https://ieeexplore.ieee.org/document/9988446>>. Acesso em: 23 jun. 2025

SYAHFITRI, Nurul Azmi et al. Digital Image Processing On Kaffir Orange Peel With Canny Edge Detection Algorithm. **Journal of Artificial Intelligence and Engineering Applications (JAIEA)**, v. 3, n. 1, p. 317–322, 5 out. 2023.

SRIVASTAV, Gaurav *et al.* Breast Cancer Detection in Mammogram Images using Machine Learning Methods and CLAHE Algorithm. In: 2022 5TH INTERNATIONAL CONFERENCE ON CONTEMPORARY COMPUTING AND INFORMATICS (IC3I). **2022 5th International Conference on Contemporary Computing and Informatics (IC3I)**. Uttar Pradesh, India: IEEE, 14 dez. 2022. Disponível em: <<https://ieeexplore.ieee.org/document/10072725/>>. Acesso em: 22 jun. 2025