



**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
GRADUAÇÃO EM ENGENHARIA BIOMÉDICA**



IASMIN MARTINS CINTRA

**AVALIAÇÃO DO CONTORNO ATIVO E DA INFLUÊNCIA DE
PRÉ-PROCESSAMENTOS NA SEGMENTAÇÃO DE NÓDULOS
MAMÁRIOS**

UBERLÂNDIA - MG
2023

IASMIN MARTINS CINTRA

**AVALIAÇÃO DO CONTORNO ATIVO E DA INFLUÊNCIA DE
PRÉ-PROCESSAMENTOS NA SEGMENTAÇÃO DE NÓDULOS
MAMÁRIOS**

Trabalho apresentado como requisito parcial de avaliação na disciplina Trabalho de Conclusão de Curso do Curso de Engenharia Biomédica da Universidade Federal de Uberlândia.

Orientador: Professor Dr. Pedro Cunha Carneiro

Assinatura do Orientador

UBERLÂNDIA - MG
2023

Dedico este trabalho à minha família,
principalmente à minha mãe, a pessoa
mais importante da minha vida.

AGRADECIMENTOS

Ao meu orientador, Dr. Pedro Cunha Carneiro, expresso minha sincera gratidão por ter aceitado a responsabilidade de me orientar e pelo constante auxílio e apoio ao longo deste trabalho. Sua paciência e compreensão foram fundamentais para me ajudar a superar os desafios e sua motivação me deu forças nos momentos de dúvida, principalmente nas etapas finais do trabalho. Serei eternamente grata por tê-lo como meu orientador.

À minha família, quero agradecer pelo apoio incondicional, incentivo e carinho que sempre me proporcionaram, não apenas durante a realização deste trabalho, mas ao longo de toda a minha vida.

À minha mãe, Rívia, por ser o meu maior exemplo de dedicação e por sempre me incentivar a ser a minha melhor versão. Minha mãe é o meu maior orgulho e todas as suas conquistas são a minha maior fonte de inspiração. Obrigada do fundo do meu coração por ser essa “pãe” incrível.

À minha avó, Iara, por sempre estar ao meu lado e acreditar em mim. Agradeço por todo o cuidado, carinho, por todos os conselhos, conversas, fofocas, almoços e jantas.

A todos os meus amigos, por todos os momentos que vivemos juntos (bons e ruins), conselhos, desabafos, festas e risadas que tornaram a jornada acadêmica e a vida em geral mais leve.

À Anna Karolinna de Sousa Machado, por dividir o mesmo neurônio comigo desde 2018, por ser a minha família de Uberlândia, por sempre me acolher e me aceitar como eu sou, pela companhia, pelos passeios na madrugada, pelos pôres do sol no arco, pelas noites de karaokê e Arquibancada, por sempre me dar colo para cochilos e choros, por ser a minha parceira de estudos e trabalhos desde Cálculo I, no primeiro semestre. Não teria chegado ao final da graduação sem você e o seu apoio.

Ao meu namorado, por toda a segurança e apoio emocional, pela motivação para concluir este trabalho e por me acalmar nos momentos de ansiedade.

Aos professores e a todos que contribuíram, de forma direta ou indireta, para minha formação e para o desenvolvimento deste trabalho.

RESUMO

O câncer de mama é a neoplasia mais comumente diagnosticada do mundo, constituindo um em cada oito diagnósticos de câncer registrados. A detecção precoce e o rastreamento mamográfico de rotina, realizados por meio da mamografia, desempenham um papel fundamental na redução da taxa de morbimortalidade associada à doença e melhoram o prognóstico e a qualidade de vida das pacientes afetadas. O diagnóstico realizado pelos radiologistas torna-se mais assertivo com auxílio do processamento digital de imagens mamográficas, que melhora a visualização de nódulos mamários e a avaliação dos exames mamográficos. Assim, o presente trabalho avalia a segmentação de nódulos em imagens mamográficas baseada em contorno ativo e a influência de técnicas de pré-processamento na qualidade da segmentação. Para a realização dos testes, foram utilizadas 47 imagens contendo nódulos do banco de imagens INbreast. O processamento foi dividido em quatro técnicas de pré-processamento e segmentação: na técnica 1 a imagem original não passou por nenhum pré-processamento, sendo segmentada diretamente; na técnica 2 foi aplicado um filtro de Wiener, precedendo o contorno ativo; na técnica 3 foi utilizada a equalização de histograma adaptativa com limitação de contraste (CLAHE) apenas nos coeficientes de aproximação da transformada discreta de *wavelet*, seguida pelo contorno ativo; e, por fim, na técnica 4 foram utilizados o filtro de Wiener e a combinação de *wavelet* com CLAHE, para que então fosse aplicado o contorno ativo. A segmentação por meio do contorno ativo utilizada baseia-se no método *level-set sparse field*. Os resultados foram avaliados por meio da excentricidade, distância de Hausdorff, quantidade de pixels brancos e da análise visual. Para ambas as análises, quantitativa e qualitativa, o padrão-ouro foi estabelecido pelo *ground-truth* disponibilizado pelo banco de imagens. As métricas forneceram uma análise sobre o formato, precisão e extensão da área do nódulo segmentado, possibilitando uma avaliação mais detalhada do efeito das técnicas utilizadas e a validação da eficácia na segmentação, juntamente à análise visual. Assim, observa-se que, para mamas pertencentes aos padrões a e b, a técnica 1 apresentou os melhores resultados. Já para as mamas mais densas, classificadas como c e d, os melhores resultados foram alcançados com a técnica 3. Portanto, observa-se que o filtro de Wiener afetou negativamente a segmentação. Dessa forma, conclui-se que a densidade mamária e o pré-processamento aplicados influenciam na qualidade da segmentação. De maneira geral, a segmentação por contorno ativo demonstrouse eficaz para todos os tipos de densidades mamárias. No entanto, algumas imagens sofreram sub ou supersegmentação. Para aprimorar os resultados encontrados neste trabalho, há necessidade de uma expansão das análises por meio da utilização de outros tipos de pré-processamento, segmentação e métricas, bem como uma maior quantidade de imagens.

Palavras-chave: Câncer de mama. Mamografia. Segmentação. Contorno Ativo. Filtro de Wiener. *Wavelet*. CLAHE.

ABSTRACT

Breast cancer is the most commonly diagnosed neoplasm worldwide, representing one in every eight cancer diagnoses recorded. Early detection and routine mammographic screening, performed through mammography, play a fundamental role in reducing the morbimortality rate associated with the disease and improve the prognosis and the quality of life of affected patients. Radiologist-conducted diagnoses become more accurate with the aid of digital processing of mammographic images, enhancing the visualization of breast nodules and the interpretability of mammographic examinations. Thus, this study assesses nodule segmentation in mammographic images based on active contour and the influence of preprocessing techniques on segmentation quality. For the conduction of the tests, 47 images containing nodules from the INbreast image database were employed. Processing was divided into four preprocessing and segmentation techniques: technique 1 involved direct segmentation without any preprocessing of the original image; technique 2 applied a Wiener filter before active contouring; technique 3 used adaptive histogram equalization with contrast limited adaptive histogram equalization (CLAHE) only on the approximation coefficients of the discrete wavelet transform, followed by active contour; and, finally, technique 4 involved using the Wiener filter and a combination of wavelet with CLAHE before active contour application. Active contour segmentation was based on the level-set sparse field method. Results were assessed using eccentricity, Hausdorff distance, quantity of white pixels and visual analysis. For both quantitative and qualitative analyses, the gold standard was established by the ground-truth provided by the image database. The metrics provided an analysis of the format, precision, and extent of the segmented nodule area, allowing a more detailed evaluation of the effects of the techniques used and the validation of segmentation efficacy alongside visual analysis. Thus, it was observed that, for breasts categorized under a and b density patterns, technique 1 yielded the best results. Conversely, for denser breasts classified as c and d patterns, the best results were achieved with technique 3. Therefore, the Wiener filter was found to negatively impact segmentation. Consequently, it is concluded that breast density and applied preprocessing significantly influence segmentation quality. Overall, active contour segmentation proved to be effective for all types of breast densities. However, some images experienced under or over-segmentation. To enhance the findings in this study, there is a need to expand the analysis by utilizing other types of preprocessing, segmentation, and metrics, as well as a larger quantity of images.

Keywords: Breast cancer. Mammography. Segmentation. Active Contour. Wiener Filter. Wavelet. CLAHE.

LISTA DE ILUSTRAÇÕES

FIGURA 1 – Ilustração do sistema de um mamógrafo	16
FIGURA 2 – - Imagens mamográficas adquiridas com as incidências CC (a) e MLO (b).	19
FIGURA 3 – Vizinhança-8 (a) e vizinhança-4 (b) do pixel $p(x, y)$	23
FIGURA 4 – Máscara 3 x 3 se deslocando ao longo da matriz $M \times N$ que define a imagem original	25
FIGURA 5 – Ilustração do processo de atuação do método de contorno ativo, em que (a) é definição inicial do contorno dentro do objeto, (b) e (c) demonstram a adaptação do <i>snake</i> e (d) ilustra o produto final da segmentação	31
FIGURA 6 – Ilustração de uma elipse circular (a) e de uma elipse alongada (b)	36
FIGURA 7 – Ilustração da Distância de Hausdorff	37
FIGURA 8 – ROIs do GT antes (a) e depois (b) do processamento no ImageJ, destacando apenas os nódulos de interesse após a remoção de microcalcificações	45
FIGURA 9 – Diagrama ilustrativo das etapas do processamento das imagens	45
FIGURA 10 – Definição interativa da área da máscara de segmentação para o contorno ativo (a) orientada pelo GT (b), gerando a máscara resultante (c) ..	47
FIGURA 11 - Exemplo da segmentação. (a) Traçado da segmentação na imagem original; (b) Lesão isolada com a técnica 1; (c) Traçado da segmentação na imagem pré-processada com a técnica 2; (d) Lesão isolada com a técnica 2; (e) Traçado da segmentação na imagem pré-processada com a técnica 3; (f) Lesão isolada com a técnica 3; (g) Traçado da segmentação na imagem pré-processada com a técnica 4; (h) Lesão isolada com a técnica 4	48
FIGURA 12 – Imagens contendo ROIs do GT antes (a) e depois (b) do processo de preenchimento no MATLAB	50
FIGURA 13 – Resumo da metodologia	51
FIGURA 14 - Imagens resultantes após a aplicação dos pré-processamentos. (a) Imagem Original; (b) Filtro de Wiener; (c) <i>Wavelet</i> + CLAHE; (d) Filtro de	

Wiener	+	<i>Wavelet</i>	+	CLAHE	
.....					53
FIGURA 15 – Gráficos ilustrando as médias das excentricidades calculadas em diferentes escalas. Em (a) o gráfico possui escala com menor variação, enquanto em (b) a escala apresenta maior variação					54
FIGURA 16 – Gráficos ilustrando as médias das distâncias de Hausdorff em relação aos GTs calculadas em diferentes escalas. Em (a) o gráfico possui escala com menor variação, enquanto em (b) a escala apresenta maior variação					56
FIGURA 17 – Gráficos ilustrando as médias das quantidades de pixels brancos presentes nas imagens calculadas em diferentes escalas. Em (a) o gráfico possui escala com menor variação, enquanto em (b) a escala apresenta maior variação					58
FIGURA 18 - Resultados gerados por meio da segmentação das imagens. (a) Imagem Original; (b) GT binarizado e preenchido da imagem original; (c) Imagem original sobreposta com o contorno ativo (técnica 1); (d) ROI binarizada após a segmentação com a técnica 1; (e) Imagem pré-processada com filtro de Wiener sobreposta com o contorno ativo (técnica 2); (f) ROI binarizada após a segmentação com a técnica 2; (g) Imagem pré-processada com <i>Wavelet</i> + CLAHE sobreposta com o contorno ativo (técnica 3); (h) ROI binarizada após a segmentação com a técnica 3; (i) Imagem pré-processada com Filtro de Wiener + <i>Wavelet</i> + CLAHE sobreposta com o contorno ativo (técnica 4); (j) ROI binarizada após a segmentação com a técnica 4					61
FIGURA 19 - Resultados gerados por meio da segmentação das imagens. (a) Imagem Original; (b) GT binarizado e preenchido da imagem original; (c) Imagem original sobreposta com o contorno ativo (técnica 1); (d) ROI binarizada após a segmentação com a técnica 1; (e) Imagem pré-processada com filtro de Wiener sobreposta com o contorno ativo (técnica 2); (f) ROI binarizada após a segmentação com a técnica 2; (g) Imagem pré-processada com <i>Wavelet</i> + CLAHE sobreposta com o contorno ativo (técnica 3); (h) ROI binarizada após a segmentação com a técnica 3; (i) Imagem pré-processada com Filtro de Wiener + <i>Wavelet</i> + CLAHE sobreposta com o contorno ativo (técnica 4); (j) ROI					

binarizada após a segmentação com a técnica 4 62

FIGURA 20 - Resultados gerados por meio da segmentação das imagens. (a) Imagem Original; (b) GT binarizado e preenchido da imagem original; (c) Imagem original sobreposta com o contorno ativo (técnica 1); (d) ROI binarizada após a segmentação com a técnica 1; (e) Imagem pré-processada com filtro de Wiener sobreposta com o contorno ativo (técnica 2); (f) ROI binarizada após a segmentação com a técnica 2; (g) Imagem pré-processada com *Wavelet* + CLAHE sobreposta com o contorno ativo (técnica 3); (h) ROI binarizada após a segmentação com a técnica 3; (i) Imagem pré-processada com Filtro de Wiener + *Wavelet* + CLAHE sobreposta com o contorno ativo (técnica 4); (j) ROI binarizada após a segmentação com a técnica 4 64

FIGURA 21 - Resultados gerados por meio da segmentação das imagens. (a) Imagem Original; (b) GT binarizado e preenchido da imagem original; (c) Imagem original sobreposta com o contorno ativo (técnica 1); (d) ROI binarizada após a segmentação com a técnica 1; (e) Imagem pré-processada com filtro de Wiener sobreposta com o contorno ativo (técnica 2); (f) ROI binarizada após a segmentação com a técnica 2; (g) Imagem pré-processada com *Wavelet* + CLAHE sobreposta com o contorno ativo (técnica 3); (h) ROI binarizada após a segmentação com a técnica 3; (i) Imagem pré-processada com Filtro de Wiener + *Wavelet* + CLAHE sobreposta com o contorno ativo (técnica 4); (j) ROI binarizada após a segmentação com a técnica 4 65

LISTA DE TABELAS

TABELA 1 – Resumo dos trabalhos relacionados que utilizam de técnicas de contornos ativos (OV: <i>overlap value</i> , RE: <i>recall</i> , ACC: acurácia, SEN: sensibilidade, VPP: valor preditivo positivo, Js: <i>jaccard</i> , DSC: coeficiente de similaridade <i>Dice</i> , PFs: <i>PFscore</i> , PRE: precisão, HaD: distância de Hausdorff)	41
TABELA 2 – Processamento utilizado para cada técnica	52
TABELA 3 - Valores médios da excentricidade e seus respectivos desvios padrões calculados para o GT e cada uma das técnicas utilizadas no processamento	54
TABELA 4 - Valores médios da distância de Hausdorff e seus respectivos desvios padrões calculados para cada uma das técnicas utilizadas no processamento	56
TABELA 5 - Valores médios da quantidade de pixels brancos presentes nas imagens e seus respectivos desvios padrões calculados para o GT e cada uma das técnicas utilizadas no processamento	58

LISTA DE ABREVIATURAS E SIGLAS

ACC – Acurácia

ACM - Contorno Ativo

ACWE - Contorno ativo sem borda

ADF - Filtragem de difusão anisotrópica

AEC - *Automatic Exposure Control*

ALSSM - Método de segmentação baseado em conjuntos de níveis adaptativos

a-Se - Selênio amorfo

BI-RADS - *Breast Imaging Reporting and Data System*

CC - Incidência crânio-caudal

CLAHE - Equalização de histograma adaptativa com limitação de contraste

CO - Filtragem *Close-Open*

CR - *Computed Radiography*

Csl - Iodeto de céσιο

CVM - Contorno ativo *level set* de Chan-veese

DICOM - *Digital Imaging and Communications in Medicine*

DSC - Coeficiente de similaridade *Dice*

EM - Filtragem Gaussiana + contorno ativo baseado em borda

FFDM - *Full Field Digital Mammography*

FN - Falso-negativo

FP - Falso-positivo

GAC - Contorno ativo geométrico

GEACM - Contorno ativo *level set* baseado em borda

GT - *Ground-truth*

HaD - *Hausdorff distance*

HE - Equalização de histograma

Js – *Jaccard*

MLO - Incidência médio-lateral oblíqua

OV - *Overlap value*

PACM - Contorno ativo paramétrico

PDI - Processamento digital de imagens

PDSS - Segmentação Seletiva *Primal-Dual*

PFs – *PF-score*

PRE - Precisão

PSP - *Photostimulable Phosphor*

Picture element - Elemento de imagem

ppi - Pixels por polegada

RE - *Recall*

ROIs - Regiões de interesse

SEN – Sensibilidade

SSLS - Segmentação de espiculação usando conjuntos de níveis

TWC - Transformada Contínua de *Wavelet*

TWD - Transformada Discreta de *Wavelet*

VN - Verdadeiro-negativo

VP - Verdadeiro-positivo

VPP - Valor preditivo positivo

SUMÁRIO

1 INTRODUÇÃO	13
1.1 Objetivos	14
1.1.1 Objetivos específicos	14
2 DESENVOLVIMENTO	15
2.1 Mamografia	15
2.1.1 Mamografia Digital	19
2.2 Processamento Digital de Imagens	21
2.2.1 Imagem Digital	21
2.2.2 Pré-processamento	25
2.2.2.1 Filtro de Wiener	25
2.2.2.2 Transformada <i>Wavelet</i>	27
2.2.2.3 CLAHE	28
2.2.3 Segmentação	30
2.2.3.1 Método do Contorno Ativo	30
2.2.3.2 Método do Contorno Ativo <i>Level-set Sparse Field</i>	34
2.3 Métricas	35
2.3.1 Excentricidade	35
2.3.2 Distância de Hausdorff	36
2.4 Estado da Arte	37
3 METODOLOGIA	43
3.1 Banco de imagens	43
3.2 Processamento	44
3.3 Métricas	49
4 RESULTADOS E DISCUSSÕES	52
4.1 Resultados quantitativos e discussões.....	53
4.1.1 Excentricidade	53
4.1.2 Distância de Hausdorff	55
4.1.3 Quantidade de pixels brancos presente nas imagens	57
4.2 Resultados qualitativos – análise visual	60
4.3 Comparação entre resultados qualitativos e quantitativos e discussões	66

5 CONCLUSÕES	67
REFERÊNCIAS	70

1 INTRODUÇÃO

Em escala global, o câncer de mama emerge como a neoplasia mais comumente diagnosticada, constituindo aproximadamente um em cada oito diagnósticos de câncer registrados. De acordo com o registro no banco de dados GLOBOCAN 2020, esse tipo de câncer resultou em cerca de 2,3 milhões de diagnósticos para ambos os sexos mundialmente, ao longo do ano de 2020, sendo também lamentavelmente reportados 685 mil casos de óbito decorrentes desta patologia (GLOBOCAN, 2021).

No Brasil, o câncer de mama é a forma mais comum de câncer entre mulheres. Conforme o relatório anual de 2022 emitido pelo Instituto Nacional do Câncer (INCA), as projeções apontam para a ocorrência de 73.610 novos casos para cada ano do triênio de 2023 a 2025 (excluindo os casos de câncer de pele não melanoma), traduzindo-se em uma taxa prevista de incidência de 66,54 casos a cada 100 mil mulheres. Adicionalmente, em 2020, a taxa de mortalidade por esta patologia foi de 16,47 óbitos por 100 mil mulheres, totalizando 17.285 mortes (INCA, 2022).

Nesse contexto, a detecção precoce desempenha um papel fundamental na redução da taxa de morbimortalidade associada à doença. Essa detecção pode ser realizada por meio do diagnóstico precoce ou do rastreamento mamográfico de rotina, por meio da mamografia digital por raios X. Uma vez que a detecção seja feita nos estágios iniciais da patologia, é possível prevenir, por meio de intervenções médicas, a manifestação de lesões mamárias sintomáticas e o desenvolvimento de metástases. Conseqüentemente, resulta em um tratamento menos agressivo e contribui para uma melhoria no prognóstico, nas chances de sobrevivência e na qualidade de vida das pacientes afetadas (American Cancer Society, 2022; Maqsood; Damaševičius; Maskeliūnas, 2022).

Entretanto, a mamografia pode gerar imagens com a presença de artefatos, ruídos ou exibir baixo contraste entre as estruturas de interesse, principalmente quando realizada em mamas densas, que caracterizam-se por uma quantidade maior de tecido fibroglandular, cuja atenuação de raios X é bem próxima à das lesões mamárias. Essas características presentes nas imagens mamográficas dificultam a interpretação por parte do radiologista e a

identificação de nódulos e microcalcificações na mama, podendo levar a equívocos (Jackson *et al.*, 1993; Souza; Angelo, 2014).

Diante dessa perspectiva, torna-se necessário submeter essas imagens a técnicas de pré-processamento digital destinadas à redução de ruídos e realce de contraste. Essa etapa envolve o uso de ferramentas computacionais que realizam operações matemáticas capazes de modificar a intensidade dos pixels que compõem a imagem. Outra etapa importante é a aplicação de técnicas de segmentação, no processamento, que têm como objetivo decompor a imagem em seus componentes. Portanto, permite identificar, delimitar e isolar as lesões do restante da imagem (Dougherty, 2009; Gonzalez; Woods, 2010).

Sendo assim, o resultado desse processamento é uma imagem mais uniforme, onde as estruturas de interesse são devidamente isoladas e possuem uma diferença de intensidade mais acentuada, aprimorando a qualidade e a interpretabilidade das imagens por meio de uma melhor visualização das estruturas mamárias. Desse modo, favorece uma análise com maior acurácia e precisão, permitindo uma detecção mais assertiva de possíveis anormalidades mamárias e, então, uma melhoria no cuidado das pacientes com câncer de mama (Dougherty, 2009; Gonzalez; Woods, 2010; INCA 2022).

1.1 Objetivo

Este estudo tem como objetivo realizar a segmentação de nódulos presentes em imagens mamográficas utilizando a técnica de contorno ativo com diferentes pré-processamentos.

1.1.1 Objetivos Específicos

- Realizar a avaliação visual da segmentação de nódulos mamários por contorno ativo;
- Avaliar a eficácia e a qualidade da segmentação de neoplasias mamárias em imagens mamográficas por contorno ativo;
- Avaliar a influência do Filtro de Wiener e da técnica de realce de contraste (*Wavelet* + CLAHE) como pré-processamento na segmentação de lesões mamárias em imagens mamográficas por contorno ativo;

- Validar a utilização da excentricidade, distância de Hausdorff e quantidade de pixels brancos na imagem como métricas comparativas para avaliar a qualidade de segmentação;
- Verificar se o padrão de densidade mamária promove diferença nos resultados de segmentação.

2 DESENVOLVIMENTO

2.1 Mamografia

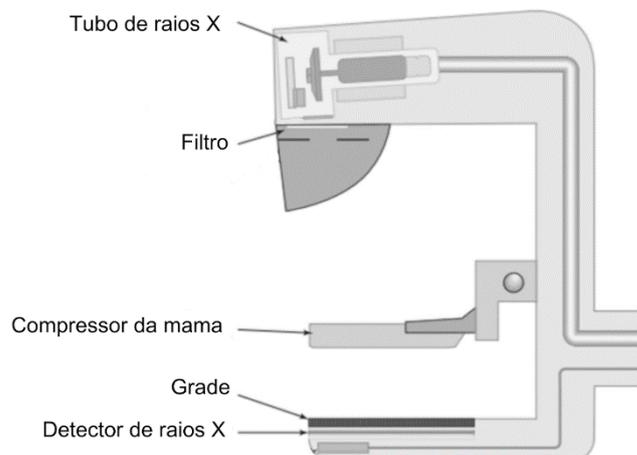
Na atualidade, a mamografia é o exame radiográfico mais eficaz para que seja feito o diagnóstico precoce de câncer de mama e o rastreamento de anormalidades clínicas no tecido mamário. Este exame sobressai-se não somente por apresentar um custo comparativamente inferior em relação a alternativas como a tomossíntese, mas também por oferecer uma exposição aceitável de radiação nos pacientes, além de possuir uma alta sensibilidade (INCA, 2007).

O equipamento utilizado para a realização desse exame é o mamógrafo, responsável pela obtenção da imagem radiográfica da mama por meio da incidência de feixes de raios X direcionados ao tecido mamário, que é composto pelo tecido glandular e adiposo, cada um com seu coeficiente de atenuação linear dos raios X (Bick, 2010; Jackson *et al.*, 1993).

A capacidade de atenuação de raios X é maior devido ao elevado contraste diferencial entre os tecidos quando a energia da radiação incidente é baixa, variando entre 15 a 35 kV. No entanto, sob essas condições, a dose de radiação administrada ao paciente é mais alta. Por outro lado, para altas energias, acima de 35 kV, a atenuação é menor, bem como a diferença intertecidual de contraste e a dose. Portanto, é necessário buscar um equilíbrio, visando submeter o paciente a menor dose possível de maneira a obter um bom contraste na imagem (Bick, 2010; Bushberg; Boone, 2011; Dougherty, 2009).

Um mamógrafo consiste em um sistema que engloba diversos componentes, tais como um tubo de raios X, um filtro, um compressor, uma grade e um detector, conforme a Figura 1 (Bushberg; Boone, 2011; Dougherty, 2009).

Figura 1 – Ilustração do sistema de um mamógrafo.



Fonte: Modificado de (Bushberg; Boone, 2011).

O tubo de raios X é composto por dois eletrodos, um de polaridade negativa (cátodo) e outro de polaridade positiva (anodo), ambos submetidos ao vácuo para evitar a dissipação de energia e também para garantir que os elétrons percorram uma trajetória direta em direção ao anodo. A radiação eletromagnética é gerada por um processo que se inicia com a aplicação de uma diferença de potencial entre os eletrodos, que varia, geralmente, no intervalo de 15 a 35 kV, a depender da densidade da mama e da fração glandular do tecido mamário. Assim, um campo elétrico é gerado (Bushberg; Boone, 2011; Dougherty, 2009; Wolbarst, 1993).

O cátodo é composto por um filamento de alto ponto de fusão. A emissão de elétrons ocorre quando uma corrente elétrica passa por ele, devido à excitação térmica proporcionada pela alta resistência do filamento. Subsequentemente, esses elétrons são acelerados e direcionados ao anodo, que possui um alvo frequentemente revestido com materiais como molibdênio, ródio ou tungstênio. Esse alvo contém um ponto focal, de 0.1 a 0.3 mm, onde ocorre a efetiva produção dos raios X a partir da colisão dos elétrons. (Dougherty, 2009; Wolbarst, 1993).

Nesse processo, a máxima energia cinética de um elétron originado a partir do cátodo, adquirida em decorrência do campo elétrico, é expressa em unidades de eV, equivalente à tensão aplicada no tubo. Durante a etapa de geração dos raios X, esse elétron sofre uma desaceleração no alvo,

experimentando uma perda de energia cinética. Essa energia é convertida majoritariamente em energia térmica e somente 1% da energia total é convertida em radiação (Dougherty, 2009).

O feixe resultante é então direcionado para fora do tubo, atravessando uma janela de berílio, passando em seguida por um filtro que consiste em uma camada fina composta de materiais como alumínio, molibdênio, ródio ou prata. O propósito desse filtro é eliminar os fótons no feixe cujas energias não contribuem significativamente para a qualidade da imagem, uma vez que são inadequados para a penetração eficaz nos tecidos da mama. A ausência desse filtro resultaria em um aumento da dose de radiação absorvida pelo paciente (Bushberg; Boone, 2011; Dougherty, 2009).

Os raios X característicos estão intrinsecamente ligados ao material do alvo, pois resultam das discrepâncias nos níveis de energia dos átomos presentes no alvo. A qualidade e quantidade dos fótons são alteradas pela tensão submetida ao tubo, alterando a capacidade de penetração do feixe, e a corrente que aquece o filamento, influenciando a quantidade de elétrons gerados no cátodo, afetando, assim, a emissão de raios X pelo ânodo (Dougherty, 2009).

Os fótons interagem com o corpo humano de duas maneiras distintas: a absorção fotoelétrica, em que a energia do fóton é absorvida ao liberar um elétron da camada mais interna do átomo, contribuindo para a absorção da radiação pelo paciente e a formação da imagem; e o espalhamento Compton, onde somente uma parcela da energia do fóton é empregada na liberação do elétron e a trajetória do fóton sofre alterações, ocasionando a degradação da qualidade da imagem em decorrência de ruído e borramento (Dougherty, 2009).

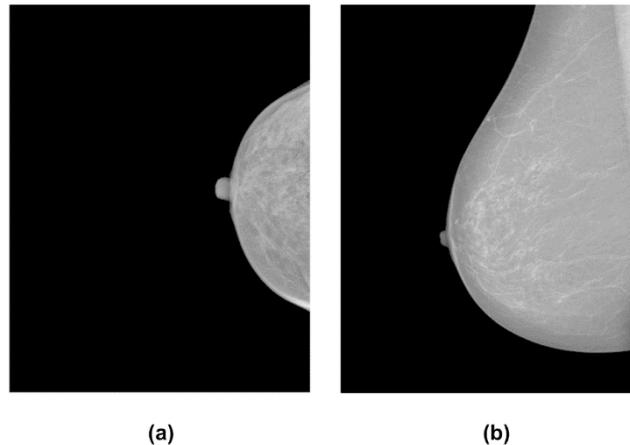
Durante a mamografia, a aquisição da imagem ocorre ao detectar a radiação que passa pelo tecido mamário. Portanto, a compressão da mama, com sua consequente aproximação do detector, é fundamental para a obtenção de uma imagem mamográfica de alta qualidade. A redução da espessura da mama resulta em uma exposição mais homogênea, o que, por sua vez, leva a uma menor dose de radiação absorvida pelo paciente e em uma diminuição no espalhamento dos fótons, reduzindo, então, o borramento da imagem. Além disso, a compressão imobiliza a mama, minimizando potenciais artefatos de movimento e a sobreposição dos tecidos mamários (Dougherty, 2009; Poulos *et al.*, 2003).

O detector é responsável pela conversão da energia do fóton em luz visível, cuja intensidade é linearmente proporcional à quantidade de energia dos fótons incidentes no detector, determinando os níveis de cinza da imagem obtida. Para que seja feita a redução da interferência proveniente da radiação espalhada, pode ser posicionada uma grade, feita a partir de uma mistura de chumbo com alumínio ou carbono, entre o suporte mamário e o sistema de aquisição de imagens. Essa grade possibilita que somente os fótons que seguem trajetórias paralelas alcancem o detector, em decorrência das propriedades absorventes do chumbo em relação à radiação (Bick, 2010; Bushberg; Boone, 2011; Dougherty, 2009).

Adicionalmente, é importante mencionar que um mamógrafo pode conter um AEC (*Automatic Exposure Control*), que define automaticamente o nível de exposição ao detector e à mama, de modo a realizar a aquisição da imagem. As funções primárias desse AEC incluem dar suporte para a predefinição da relação sinal-ruído e garantir que a dose de radiação aplicada à mama seja apropriada, sem a necessidade de controlar diretamente o brilho ou o contraste da imagem (Bick, 2010).

Com o objetivo de mapear a mama de maneira mais eficaz, são adquiridas imagens com dois posicionamentos distintos. Utilizando as técnicas de incidência crânio-caudal (CC) e incidência médio-lateral oblíqua (MLO), a mama é submetida à compressão e afastamento em relação ao músculo peitoral maior, o que, por sua vez, pode destacar de maneira mais evidente a presença de massas tumorais, que tendem a estar localizadas em proximidade a esse músculo (Mitchell; Bassett, 1988). A Figura 2 ilustra as duas técnicas de compressão abordadas.

Figura 2 - Imagens mamográficas adquiridas com as incidências CC (a) e MLO (b).



Fonte: INbreast (Moreira *et al.*, 2012).

A mama possui uma anatomia complexa com traços e detalhes singulares, visto que cada indivíduo possui uma morfologia glandular única, na qual a massa tumoral pode se manifestar. Dessa forma, alguns casos de câncer não podem ser identificados pela mamografia. Essa limitação é mais pronunciada em casos de mamas densas, majoritariamente compostas de tecido fibroglandular, cuja atenuação de raios X é semelhante à das neoplasias mamárias (Jackson *et al.*, 1993).

2.1.1 Mamografia Digital

Na mamografia digital, a energia dos raios X é convertida diretamente em um sinal elétrico através de sensores semicondutores, que posteriormente encaminham esse sinal a um computador. Em seguida, um conversor A/D transforma o sinal elétrico em uma imagem digital. Embora seja um exame com custos mais elevados, a imagem gerada, além de ter melhor qualidade e resolução de contraste, proporciona um processamento otimizado, uma vez que facilita a manipulação das imagens e o armazenamento das mesmas (Dougherty, 2009; Rowlands, 2002).

Dois diferentes sistemas de mamografia digitais podem ser aplicados: o sistema CR (*Computed Radiography*) e o sistema FFDM (*Full Field Digital Mammography*). Em sistemas CR, a operação dos detectores funciona com base

no princípio da luminescência fotoestimulável, por isso também são chamados de PSP (*Photostimulable Phosphor*). Quando os raios X atingem uma placa composta por um material fosforescente, a energia absorvida leva à libertação temporária de elétrons do cristal, que são então capturados nos sítios de aprisionamento de elétrons dentro da placa. Então, essa placa é inserida em um dispositivo de leitura que libera os elétrons das armadilhas, convertendo o sinal analógico resultante em sinal digital, que é processado por sistemas computacionais. Apesar de ser uma abordagem mais econômica, os cassetes removíveis precisam ser transportados manualmente até o leitor para que a imagem possa ser interpretada (Bick, 2010).

Por sua vez, os sistemas FFDM realizam a conversão imediata dos raios X em sinal digital. Esses sistemas podem ser classificados de acordo com os detectores utilizados, que podem ser diretos ou indiretos. Nos sistemas FFDM com detectores indiretos, o processo envolve duas etapas: inicialmente, um cintilador, como o iodeto de cério (CsI) capta e converte a energia dos raios X em fótons de luz, que é detectada, posteriormente, por uma matriz de fotodiodos, transformando esses fótons de luz em um sinal digital. No entanto, apesar da estrutura tubular em forma de agulha dos cristais de CsI, que auxilia na direção da luz para a superfície do sensor óptico, ocorre o espalhamento de luz em decorrência de imperfeições estruturais da agulha, causando assim uma deterioração na qualidade da imagem (Mahesh, 2004).

Em contrapartida, em sistemas FFDM que empregam detectores de captura direta, os fótons de raios X são diretamente absorvidos por um fotocondutor, como o selênio amorfo (a-Se). Esse fotocondutor é responsável pela conversão direta da energia dos raios X absorvidos em sinal digital. Assim, esses sistemas eliminam as possibilidades de perda de resolução decorrentes do espalhamento de luz, que são intrínsecas à captura indireta. Adicionalmente, a espessura do fotocondutor não limita a resolução espacial da imagem, mas sim o tamanho dos pixels (Mahesh, 2004).

2.2 Processamento Digital de Imagens

O uso das técnicas de processamento digital de imagens (PDI) se estende a diversas aplicações, sendo caracterizado pela captura, representação e transformação de imagens com o apoio de sistemas computacionais. Essas abordagens permitem não apenas a extração de informações das imagens, mas também o aprimoramento da qualidade visual das mesmas, com a finalidade de simplificar a visualização e interpretação tanto pelos profissionais da saúde quanto por sistemas de inteligência artificial. Isso pode resultar, por exemplo, em um diagnóstico com maior acurácia de neoplasias mamárias em imagens mamográficas (Pedrini; Schwartz, 2008).

Assim, o PDI engloba uma variedade de operações em que tanto a entrada quanto a saída são imagens, podendo ser categorizada em níveis baixo, médio e alto. No nível baixo, a fase de pré-processamento realiza operações básicas como a filtragem para redução de ruído, o realce de contraste e aprimoramento da nitidez da imagem. Já no nível médio, embora a entrada permaneça sendo imagens, as saídas consistem principalmente em atributos extraídos das mesmas por meio de processos de segmentação. Dessa forma, é possível identificar e isolar lesões da mama, viabilizando sua classificação e servindo como auxílio ao diagnóstico (Gonzalez; Woods, 2010).

Por fim, no mais elevado nível de complexidade do PDI, emergem técnicas avançadas destinadas à extração de informações mais complexas das imagens. Essas técnicas incluem o reconhecimento de objetos, a atribuição de significado aos objetos identificados, a aplicação de técnicas de aprendizado de máquina, o uso de redes neurais e a análise e reconhecimento de padrões complexos (Gonzalez; Woods, 2010).

2.2.1 Imagem Digital

No PDI, a imagem é caracterizada por uma função bidimensional, $f(x, y)$, na qual x e y correspondem às coordenadas espaciais em um plano, enquanto a magnitude f denota a intensidade ou o valor de escala de cinza associado ao ponto (x, y) nesse plano. A representação das imagens é feita por meio de estruturas matriciais com dimensões $M \times N$, em que M refere-se ao número de

linhas e N ao número de colunas presentes na matriz. Nas matrizes, os valores contidos em cada posição correspondem a um determinado nível de escala de cinza e constituem um elemento de imagem conhecido como pixel (abreviação de *picture element*) (Gonzalez; Woods, 2010; Persechino; De Albuquerque, 2015).

Uma matriz numérica de dimensões $M \times N$ é dada por (Gonzalez; Woods, 2010):

$$f(x, y) = \begin{bmatrix} f(0,0) & \cdots & f(0, N-1) \\ \vdots & \ddots & \vdots \\ f(M-1,0) & \cdots & f(M-1, N-1) \end{bmatrix} \quad (1)$$

A conversão de uma imagem analógica em formato digital se dá por meio de dois processos: a amostragem, que envolve a digitalização das coordenadas, e a quantização, que consiste na digitalização dos valores de amplitude. Sendo assim, uma amostragem adequada é um componente crítico para assegurar uma boa resolução espacial em imagens digitais. A resolução espacial é uma métrica que se refere à quantidade de pixels usados na formação da imagem, tendo uma influência direta na capacidade de representação de detalhes finos, como as microestruturas presentes em uma imagem mamográfica. A medida de resolução espacial é expressa em pixels por polegada (ppi) (Athanasiou; Fotiadis; Michaelis, 2017; Gonzalez; Woods, 2010; Persechino; De Albuquerque, 2015).

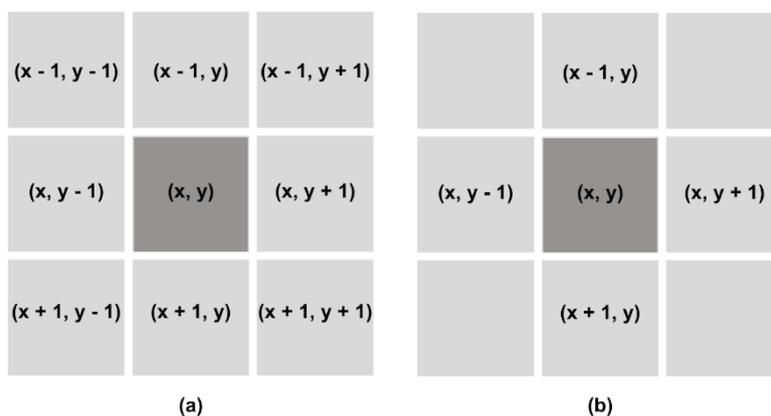
Além disso, segundo o princípio da quantização, o número de níveis de cinza possíveis em uma imagem é determinado pela quantidade de bits exigidos para representá-la. Assim, quando n denota o número de bits na imagem, o número de níveis de intensidade varia de zero a 2^{n-1} . Por exemplo, uma imagem com uma resolução de oito bits disponibiliza 256 tons de cinza distintos para visualização, abrangendo o intervalo de zero a 255. Esse valor representa a menor variação discernível de nível de intensidade em uma imagem (Gonzalez; Woods, 2010; Persechino; De Albuquerque, 2015).

O histograma de uma imagem digital representa uma aproximação da distribuição de probabilidade dos níveis de intensidade da imagem, sem

associação às informações espaciais. Dessa forma, um mesmo histograma pode ser compartilhado por diferentes imagens. Imagens com um bom contraste geralmente apresentam histogramas com uma distribuição mais uniforme em relação aos valores de intensidade, enquanto imagens de baixo contraste tendem a ter uma maior concentração em torno da média (Persechino; De Albuquerque, 2015).

Excluindo-se os pixels de fronteira, localizados nas margens da imagem, cada pixel possui oito vizinhos próximos, sendo quatro deles nas direções diagonais, um par na direção horizontal e outro par na vertical. Tomando p como um pixel nas coordenadas (x, y) , essa vizinhança-8 inclui os pixels situados em $(x + 1, y)$, $(x - 1, y)$, $(x, y + 1)$, $(x, y - 1)$, $(x + 1, y + 1)$, $(x + 1, y - 1)$, $(x - 1, y + 1)$ e $(x - 1, y - 1)$. Da mesma forma, é possível que os pixels só se relacionem com quatro vizinhos imediatos, dentro da vizinhança-4, situados na direção vertical e horizontal, ou seja, dispostos em $(x + 1, y)$, $(x - 1, y)$, $(x, y + 1)$, $(x, y - 1)$. Para os pixels de fronteira, é necessário preencher as posições ausentes com zeros ou com réplicas dos pixels. A Figura 3 ilustra a vizinhança-8 e a vizinhança-4 de um pixel (Gonzalez; Woods, 2010; Persechino; De Albuquerque, 2015).

Figura 3 – Vizinhança-8 (a) e vizinhança-4 (b) do pixel $p(x, y)$.



Fonte: Modificado de (Persechino; De Albuquerque, 2015).

Existem abordagens no PDI que se fundamentam nas interações entre os pixels de uma área específica, que colaboram para que seja feita a identificação de fronteiras e bordas presentes na imagem, o que é essencial para a

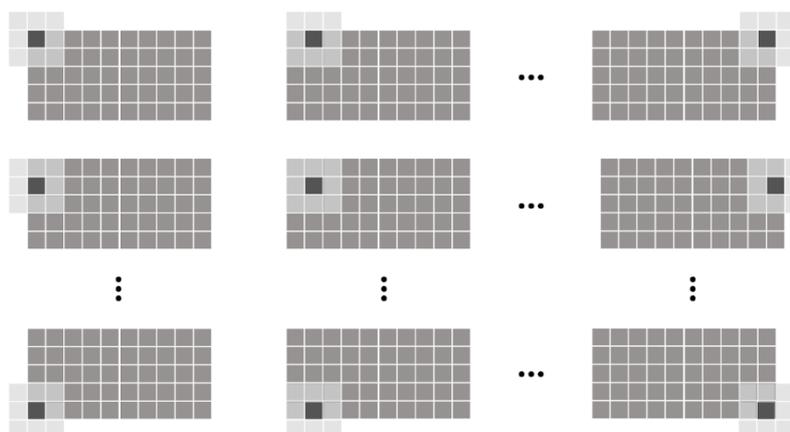
segmentação de estruturas. Logo, é importante definir previamente o conceito de vizinhança que será empregado no método de processamento em questão. Na vizinhança-8, por exemplo, a fronteira é definida como um conjunto de pixels pertencentes à região que compartilham pelo menos um vizinho com o fundo da imagem. Já a borda é caracterizada nessa vizinhança pela presença de descontinuidades e variações acentuadas na intensidade entre os pixels, identificadas pelo cálculo de derivadas e a aplicação de um limiar predefinido. (Gonzalez; Woods, 2010; Persechino; De Albuquerque, 2015).

O processamento direto dos pixels nas imagens é realizado por meio das técnicas no domínio espacial, permitindo a manipulação dos níveis de intensidade dos pixels baseada nas interações com seus vizinhos. Esse procedimento é representado pela seguinte equação, em que a imagem de entrada é $f(x, y)$, a imagem de saída é $g(x, y)$ e T é o operador que será aplicado, podendo ser uma transformação qualquer, linear ou não Gonzalez; Woods, 2010, Persechino; De Albuquerque, 2015):

$$g(x, y) = T[f(x, y)] \quad (2)$$

Para efetuar o PDI no domínio espacial, começa-se por definir uma matriz que contém os coeficientes desejados, frequentemente referida como máscara ou *kernel*. Então, essa máscara é deslocada por todos os pixels na imagem, aplicando o operador T a cada pixel da vizinhança. Em seguida, o pixel central é atualizado com o resultado da operação, e a imagem de saída é obtida após a aplicação desse processo a todas as linhas e colunas, varrendo todos os pixels da imagem original. O processo de deslocamento da máscara ao longo da matriz que define a imagem original é ilustrado na Figura 4 (Gonzalez; Woods, 2010; Persechino; De Albuquerque, 2015).

Figura 4 – Máscara 3 x 3 se deslocando ao longo da matriz $M \times N$ que define a imagem original.



Fonte: Modificado de (Persechino; De Albuquerque, 2015).

2.2.2 Pré-processamento

Em uma imagem mamográfica, a detecção do nódulo é dificultada pela presença de artefatos, como ruídos, e pela limitação de contraste entre as estruturas de interesse. Dessa forma, ela deve ser submetida ao pré-processamento, o estágio inicial de otimização da imagem, tornando-a apta para a subsequente extração e interpretação de informações nas outras etapas do PDI. Ele engloba técnicas que incluem a redução de ruídos, realce de bordas e realce de contraste (Ciecholewski, 2017; Gonzalez; Woods, 2010; Souza; Angelo, 2014).

A seguir serão abordadas as técnicas de pré-processamento que serão utilizadas ao longo deste estudo.

2.2.2.1 Filtro de Wiener

O filtro de Wiener, frequentemente referido como filtro de mínimo erro quadrático médio, é uma ferramenta adaptativa de filtragem passa-baixa, sendo empregado como uma técnica de restauração em imagens degradadas por ruído, tornando-as mais nítidas mediante um processo de suavização. Dessa forma, configura-se como uma técnica de redução de dados, porém com a menor

perda de informação possível (Gonzalez; Woods, 2010; Romualdo; Vieira; Schiabel, 2009).

Esse método considera tanto a imagem original quanto o ruído como variáveis aleatórias, cujas características espectrais são previamente conhecidas, e visa reduzir ao mínimo possível o erro quadrático médio entre o sinal estimado e o sinal original, maximizando a relação sinal ruído. Sendo assim, ele tem como objetivo minimizar a distorção gerada pelo ruído, proporcionando uma recuperação da qualidade da imagem original (Gonzalez; Woods, 2010; Vaseghi, 2008).

Em uma imagem não corrompida, representada por f , e uma imagem estimada, \hat{f} , a medida de erro pode ser calculada por (Gonzalez; Woods, 2010):

$$e^2 = E\{(f - \hat{f})^2\} \quad (3)$$

onde E representa o valor esperado do argumento. Para equacionar o mínimo da função de erro, no domínio da frequência, deve-se assumir que o ruído e a imagem não estejam correlacionados e que ambos possuam média igual a zero. Somado a isso, a intensidade dos pixels da estimativa deve ser expressa como uma função linear dos níveis presentes na imagem a ser restaurada. Dessa forma, o mínimo da função de erro é dado por (Gonzalez; Woods, 2010):

$$\begin{aligned} \hat{F}(u, v) &= \left[\frac{H^*(u, v)S_f(u, v)}{S_f(u, v)|H(u, v)|^2 + S_n(u, v)} \right] G(u, v) \\ &= \left[\frac{H^*(u, v)}{|H(u, v)|^2 + S_n(u, v)/S_f(u, v)} \right] G(u, v) \\ &= \left[\frac{1}{H(u, v)} \frac{|H(u, v)|^2}{|H(u, v)|^2 + S_n(u, v)/S_f(u, v)} \right] G(u, v) \end{aligned} \quad (4)$$

em que $\hat{F}(u, v)$ é a imagem estimada no domínio da frequência; $H(u, v)$ é a transformada da função de degradação; $G(u, v)$ é a transformada da imagem degradada; $H^*(u, v)$ é o conjugado complexo de $H(u, v)$; o termo $|H(u, v)|^2$ é

igual a $H^*(u, v) H(u, v)$, uma vez que o quadrado da magnitude de um número complexo é o produto do valor complexo pelo seu conjugado; $S_n(u, v) = |N(u, v)|^2$ é o espectro de potência do ruído e $S_f(u, v) = |F(u, v)|^2$ é o espectro de potência da imagem não degradada.

Dado que a saída da filtragem corresponde a uma função no domínio da frequência, a reconstrução da imagem restaurada requer a aplicação da transformada de Fourier inversa à imagem estimada $\hat{F}(u, v)$ (Dougherty, 2009; Gonzalez; Woods, 2010).

2.2.2.2 Transformada *Wavelet*

A aplicação da transformada *wavelet* é eficaz para realçar o contraste de imagens, além de suavizar ruídos e permitir que as imagens tenham uma representação multiescala. Isso se deve ao processo de decomposição do sinal em múltiplas escalas, no domínio do tempo e da frequência. Então, a técnica seleciona a escala adequada, atenuando a influência de outras escalas (Daubechies, 1992).

A *wavelet-mãe* selecionada constitui a função básica oscilatória de suporte utilizada para a geração das *wavelets* por meio da dilatação e deslocamentos do sinal. As transformadas podem ser categorizadas como contínuas (TWC - Transformada Contínua de *Wavelet*) ou discretas (TWD - Transformada Discreta de *Wavelet*). Em uma TWD, a configuração da dilatação e da translação como deslocamento permite uma análise multirresolução do sinal, em tempo e frequência, de acordo com a equação da TWD (Chui, 2016; Daubechies, 1992; Sablón; Mendez; Iano, 2010):

$$TWD(m, n) = \frac{1}{\sqrt{a_0^m}} \int_{-\infty}^{\infty} f(x) \psi * (a_0^{-m}x - k) dx \quad (5)$$

em que m representa a escala e n o deslocamento, ambos $\in \mathbb{Z}$. A dilatação, representada por a , é submetida a uma discretização exponencial $a = (a_0^m)$. A translação, dada por $b = k$, é sujeita a uma discretização proporcional à a , $b = b_0 \cdot n_0 \cdot a_0^m$. As constantes a_0 e b_0 denotam os passos discretos de escalonamento

e deslocamento, respectivamente. O parâmetro ψ equivale a $(at - b)$ e, por fim, k corresponde a uma amostra específica do sinal de entrada $f(x)$.

Mediante ao trabalho desenvolvido por Mallat, é possível obter a aproximação e os detalhes de um sinal mediante a aplicação de um algoritmo piramidal baseado em convoluções com filtros de espelho de quadratura. Nesse contexto, o sinal é decomposto em duas componentes distintas, de acordo com a Equação (6) (Mallat, 1989, 1999):

$$f_{2^{j+1}}(x) = f_{2^j}(x) + D_{2^j} f(x) \quad (6)$$

O termo referente ao coeficiente de aproximação ($f_{2^j}(x)$) agrega as componentes de baixas frequências do sinal, enquanto o coeficiente de detalhe ($D_{2^j} f(x)$) indica as componentes de alta frequência, sendo subdividido nas direções vertical, horizontal e diagonal. Como resultado, a aplicação dessa técnica resulta em quatro níveis de decomposição: aproximação, vertical, horizontal e diagonal.

Após a etapa de decomposição, aplica-se uma operação de limiarização, também conhecida como *thresholding*, nos coeficientes obtidos. Esse método tem como objetivo a minimização do ruído presente no sinal, efetuando a eliminação dos níveis de intensidade inferiores ao limiar (*threshold*) predefinido. Em seguida, é executada a transformada *wavelet* inversa nos coeficientes de aproximação e detalhe, culminando na obtenção de uma imagem filtrada (Donoho; Johnstone, 1995).

2.2.2.3 CLAHE

O método conhecido como *Contrast Limited Adaptive Histogram Equalization* (CLAHE) representa uma abordagem indireta de ajuste de contraste, que envolve a alteração das configurações do histograma da imagem por meio da equalização adaptativa de histograma com limitação de contraste. A CLAHE, cuja proposta inicial foi formulada por Pizer e seus colaboradores, emprega um método que adapta o histograma original tendo como base um histograma predefinido (Lu *et al.*, 2010; Pizer *et al.*, 1987).

A implementação da técnica CLAHE requer a parametrização de alguns elementos, incluindo a quantidade de janelas nas quais a imagem será dividida. O número de janelas exerce um impacto direto na qualidade da equalização. Quanto maior esse número, maior a degradação na qualidade. Contudo, a escolha do tamanho de janelas ideal é feita por meio de experimentação prática e varia de acordo com o tipo da imagem de origem (Carneiro, 2019).

Na CLAHE, os valores excedentes são redistribuídos para outras intensidades a depender do limiar de corte, que varia no intervalo de zero a um. Esse parâmetro controla a quantidade de pixels que serão redistribuídos. Adicionalmente, é necessário selecionar a distribuição de probabilidade que orientará a redistribuição dos pixels e, conseqüentemente, a transformação do contraste. Para esse propósito, adota-se funções uniforme, exponencial ou Rayleigh. É esperado que o histograma da imagem resultante reflita o padrão da função aplicada. No entanto, em imagens mamográficas, observa-se que a escolha da distribuição não causa uma variação substancial nos resultados (Carneiro, 2019; Carneiro *et al.*, 2019; Rezende Junior; Carneiro; Patrocínio, 2018).

O cálculo efetuado para a aplicação da CLAHE é expresso na equação a seguir (Civcik *et al.*, 2015):

$$g = [g_{max} - g_{min}]p(f) + g_{min} \quad (7)$$

onde g representa o novo valor de pixel após o processamento CLAHE, g_{min} e g_{max} são os valores mínimos e máximos do pixel e $p(f)$ denota a função de probabilidade de distribuição acumulada.

A fim de evitar a amplificação de componentes indesejados no sinal, a CLAHE deve ser empregada de forma subsequente à etapa de remoção de ruído. Além disso, após a etapa final dessa técnica, aplica-se uma interpolação bilinear para eliminar possíveis artefatos de borda que possam ter sido inadvertidamente introduzidos pela CLAHE (Zhao; Georganas; Petriu, 2010; Zuiderveld, 1994).

2.2.3 Segmentação

A segmentação de uma imagem envolve a subdivisão da mesma em regiões distintas, as quais não se sobrepõem, resultando na evidenciação das estruturas em relação ao plano de fundo da imagem, bem como das fronteiras entre as regiões. Portanto, essa técnica é responsável por alterar e melhorar a representação da própria imagem. Assim, caracteriza-se como a etapa mais crítica do PDI, uma vez que seu resultado irá constituir a base para análises posteriores mais detalhadas. (Dougherty, 2009; Gonzalez; Woods, 2010; Persechino; De Albuquerque, 2015).

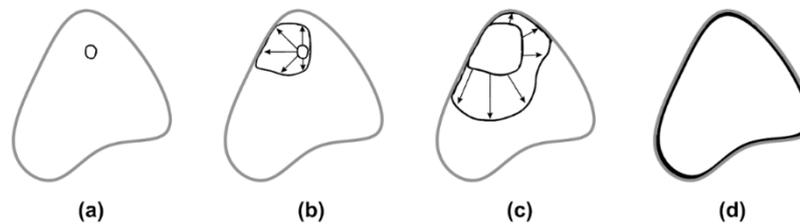
Para uma segmentação precisa, os pixels de uma mesma região devem possuir cor, textura ou nível de cinza homogêneos ou semelhantes, enquanto os pixels adjacentes a essa região devem ter valores distintos. Em abordagens que consideram a homogeneidade das informações, a segmentação envolve a combinação de pixels que atendem a critérios de similaridade, ao passo que em estratégias que exploram descontinuidades, a segmentação é orientada por alterações temporárias nos valores de intensidade (Singh *et al.*, 2021).

Essa técnica, capaz de isolar as irregularidades e anormalidades presentes em uma imagem mamográfica, é muito utilizada como apoio para o auxílio ao diagnóstico de câncer de mama. Ou seja, a localização precisa de uma lesão mamária promove maior interpretabilidade a uma imagem mamográfica e oferece um melhor direcionamento para procedimentos diagnósticos futuros (Dougherty, 2009; Gonzalez; Woods, 2010).

2.2.3.1 Método de Contorno Ativo

O princípio subjacente ao método de Contorno Ativo (ACM), também denominado *snake*, envolve a definição inicial do contorno ao redor ou dentro do objeto de interesse, com a criação de segmentos de reta que se estendem até as margens internas da área a ser segmentada. Então, essa curva é submetida a uma otimização contínua visando se adequar da melhor maneira possível à forma da região a ser segmentada, como ilustrado na Figura 5 (De Alexandria *et al.*, 2011; Kass; Witkin; Terzopoulos, 1987).

Figura 5 – Ilustração do processo de atuação do método de contorno ativo, em que (a) é definição inicial do contorno dentro do objeto, (b) e (c) demonstram a adaptação do *snake* e (d) ilustra o produto final da segmentação.



Fonte: Modificado de (Alberto, 2022).

Essa otimização é feita de maneira iterativa, buscando, a cada iteração, a minimização da energia associada à curva ao modificar o contorno inicial de acordo com a interação de forças internas e externas que atuam sobre ele. A energia interna é determinada pela forma e localização do contorno. Assim, ela direciona o *snake* em direção a atributos distintivos, como linhas e contornos. Enquanto isso, a energia externa varia de acordo com o gradiente da imagem. Ou seja, as forças externas trabalham para posicionar o *snake* nas proximidades do ponto de menor energia (De Alexandria *et al.*, 2011; Kass; Witkin; Terzopoulos, 1987; Liu *et al.*, 2006).

Portanto, o deslocamento do contorno é determinado mediante o cálculo das energias internas e externas e à análise da vizinhança de cada ponto na área de interesse, resultando no movimento em direção à coordenada com menor energia funcional total atrelada. Para uma representação paramétrica da posição de um *snake*, tem-se a equação (Kass; Witkin; Terzopoulos, 1987; Nixon; Aguado, 2019):

$$v(s) = (x(s), y(s)) \quad (8)$$

sendo $v(s)$ o conjunto de pontos que constituem o contorno ativo, com suas respectivas coordenadas x e y . A partir da Equação (8), a equação da energia funcional total (E_{snake}) é escrita como:

$$E_{snake}(v(s)) = \int_{s=0}^1 \{E_{int}(v(s)) + E_{ext}(v(s))\} ds \quad (9)$$

em que E_{int} e E_{ext} representam, respectivamente, a energia interna e externa da curva e o intervalo de $s = [0,1]$ equivale ao comprimento do arco normalizado na extensão do contorno.

A energia interna, por sua vez, é constituída por duas forças, E_1 e E_2 , podendo ser escrita conforme a seguinte equação (Souza; Angelo, 2014):

$$E_{int} = E_1 + E_2 \quad (10)$$

Ao substituir as funções E_1 e E_2 , tem-se:

$$E_{int} = \frac{(\alpha(s)|v'(s)|^2 + \beta(s)|v''(s)|^2)}{2} \quad (11)$$

O termo de primeira ordem E_1 refere-se à energia elástica de alongamento, influenciada pelo parâmetro $\alpha(s)$, responsável por regular a continuidade do contorno. Dessa forma, um valor mais elevado resulta em um maior espaçamento entre os pontos representados. Nesse sentido, a minimização dessa energia, identificando pontos em que o valor de $v'(s)$ seja baixo, implica na aproximação dos pontos e na concentração da curva (De Alexandria *et al.*, 2011; Nixon; Aguado, 2019; Liu *et al.*, 2006).

Por outro lado, o parâmetro $\beta(s)$, associado ao termo de segunda ordem, controla a energia de curvatura do *snake*. Um valor elevado sugere contornos com ângulos mais agudos, enquanto um valor baixo indica contornos de aspecto mais suave. Seu valor mínimo é alcançado quando $v''(s) = 0$, ou seja, quando a curva assume a forma de uma reta, possibilitando que seja desenvolvido um canto em um ponto. Sendo assim, durante o processo de minimização, enfatizar o coeficiente E_2 induz o *snake* a diminuir sua curvatura (De Alexandria *et al.*, 2011; Nixon; Aguado, 2019; Liu *et al.*, 2006).

A energia externa atua para atrair o *snake* em direção a características de baixa intensidade, incluindo informações de brilho e detalhes relacionados às bordas do objeto. Assim, cria-se um mapa de borda da imagem. Essa função tem uma importância fundamental ao agir como um mecanismo compensatório que impede que a curva do *snake* se retraia excessivamente ou sobre si mesma, o que poderia resultar na diminuição da acuidade na identificação dos contornos presentes na imagem (De Alexandria *et al.*, 2011; Kass; Witkin; Terzopoulos, 1987; Nixon; Aguado, 2019).

Geralmente, a energia externa é determinada por (Kass; Witkin; Terzopoulos, 1987):

$$E_{ext}(x, y) = -|\nabla[G_{\sigma} \cdot I(x, y)]|^2 \quad (12)$$

em que $I(x, y)$ é o gradiente da imagem, ∇ é o operador gradiente e G_{σ} é uma gaussiana centrada no ponto (x, y) de variância σ com o objetivo de disseminar o impacto da energia por toda a área circundante do ponto onde é empregada.

Portanto, a equação da energia funcional total Equação (9) pode ser reescrita na Equação (13), com a substituição dos termos da energia interna e externa:

$$E_{snake} = \int_{s=0}^1 \left\{ \left(\frac{(\alpha(s)|v'(s)|^2 + \beta(s)|v''(s)|^2)}{2} \right) + (-|\nabla[G_{\sigma} \cdot I(x, y)]|^2) \right\} ds \quad (13)$$

No entanto, esse método tradicional de contorno ativo paramétrico se caracteriza por um escopo de captura restrito, permitindo apenas a extração de objetos em proximidade ao contorno inicial. Além disso, ele revela restrições significativas em termos da adaptabilidade da curva, o que, por sua vez, impede a segmentação de bordas convexas, proeminências ou pontos de bifurcação (Souza; Angelo, 2014).

2.2.3.2 Método de Contorno Ativo *Level-set Sparse Field*

No escopo deste estudo foi utilizada a função *activecontour()* como o método de segmentação baseado em contorno ativo. Esta função é embasada na abordagem denominada *Level-set Sparse Field*, uma técnica que trata uma superfície 3D como o conjunto de níveis de um volume amostrado de forma discreta. Isso viabiliza uma deformação da superfície com maior flexibilidade e eficiência, sem a exigência de reparametrização, tornando mais simples a avaliação da geometria intrínseca do modelo. Dessa forma, combina as vantagens de uma abordagem *Level-set* com a eficiência computacional e precisão de uma representação paramétrica (Whitaker, 1998).

O *Level-Set Sparse Field* opera com listas de pontos de grade para representar o conjunto de nível zero, bem como pontos adjacentes a esse conjunto, em uma curva de nível com sua posição controlada pelos valores dos pontos. No contexto da segmentação, esse conjunto pode ser considerado como uma superfície virtual tridimensional ou um subconjunto do campo 3D (Saien; Moghaddam; Fathian, 2018; Whitaker, 1998).

Esse subconjunto é composto por pontos ativos, os quais desempenham um papel fundamental na definição do contorno do objeto de interesse, sendo pontos de controle para um conjunto de nível zero próximo. Esses pontos ativos podem ser acessados por meio de uma lista encadeada para identificar e localizar os conjuntos ativos (Saien; Moghaddam; Fathian, 2018; Whitaker, 1998).

O conjunto de nível (nível zero) representa, de forma implícita, a superfície segmentada e é definido pela função Lipschitz $\phi(x): \rightarrow R$. Inicialmente, essa função é expressa como uma função de distância assinada, na qual os valores são negativos dentro da superfície. A equação que descreve a evolução do conjunto de nível é a seguinte (Ukwatta *et al.*, 2013):

$$\frac{\partial \phi(x)}{\partial t} + \nabla E |\nabla \phi(x)| = 0$$

(14)

Nessa equação, a função $\phi(x)$ evolui com o tempo até convergir para um mínimo de energia, descrevendo a mudança na superfície ao longo do processo. O termo E é a função objetiva, que engloba termos de energia interna e externa.

Durante o processo de deformação do nível zero, o algoritmo se concentra principalmente em uma fina camada de subconjuntos próxima aos pontos ativos. Portanto, a cada passo iterativo, o algoritmo percorre exclusivamente os pontos que estão próximos à curva de nível. Ou seja, ele realiza cálculos e atualizações apenas em um pequeno número de pontos (Saien; Moghaddam; Fathian, 2018; Whitaker, 1998).

Essa estratégia tem um impacto notável na redução da complexidade computacional, uma vez que a quantidade de cálculos envolvidos está mais relacionada à dimensionalidade da superfície do que ao seu volume. Isso contrasta com os métodos de *level-set* tradicionais, que enfrentam desafios significativos de escalabilidade à medida que a dimensionalidade aumenta (Saien; Moghaddam; Fathian, 2018; Ukwatta *et al.*, 2013; Whitaker, 1998).

2.3 Métricas

2.3.1 Excentricidade

A excentricidade é um descritor de forma. Trata-se de uma métrica que quantifica o quanto a forma de um objeto se difere de uma circunferência. Em uma imagem bidimensional, sua definição se dá por meio da relação entre a distância entre os focos da elipse que circunscribe o objeto e o comprimento de seu eixo principal, conforme expressa pela Equação (15) (Valarmathie; Sivakrithika; Dinakaran, 2016):

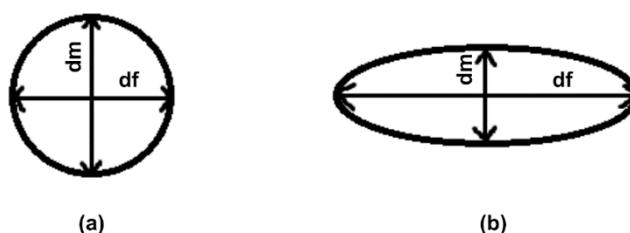
$$E = \sqrt{1 - \left(\frac{dm}{df}\right)^2} \quad (15)$$

em que E é a excentricidade, df é a distância entre os focos da elipse e dm é o comprimento do eixo principal.

Os valores da excentricidade pertencem ao intervalo entre zero e um. De acordo com princípios geométricos, o círculo é uma elipse com excentricidade

nula e uma elipse com excentricidade igual a um é, na verdade, uma parábola. Portanto, quanto menor for o valor calculado para a excentricidade, mais circular será a elipse. Por outro lado, quanto maior for o valor obtido, mais alongada é a elipse, ou seja, menos circular ela será (Soares, 2020).

Figura 6 – Ilustração de uma elipse circular (a) e de uma elipse alongada (b).



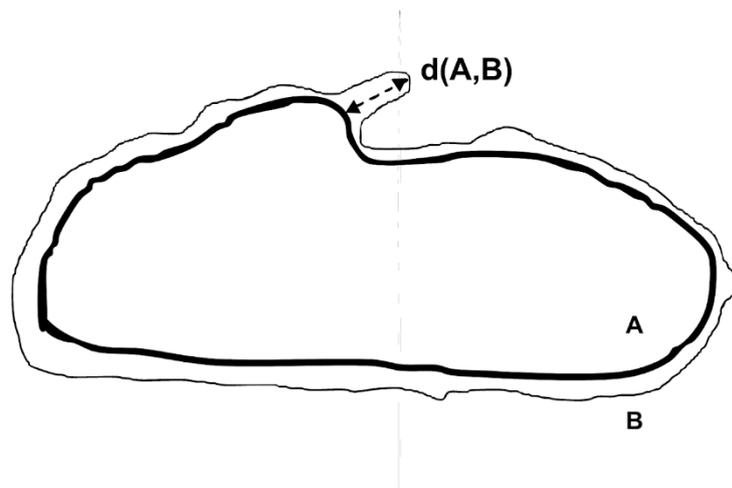
Fonte: Modificado de (Soares, 2020).

Observando a Figura 6, fica evidente que na elipse da Figura 6 (a), os valores de dm e df são idênticos. Assim, a excentricidade resultante é o valor mínimo (zero), o que caracteriza a elipse como um círculo. Em contrapartida, na elipse da Figura 6 (b), onde o comprimento de df excede o de dm , a excentricidade tem um valor maior e a elipse é visivelmente menos circular e mais alongada.

2.3.2 Distância de Hausdorff

A distância de Hausdorff, do inglês *Hausdorff Distance* (HaD) é uma abstração matemática empregada na avaliação da similaridade entre dois conjuntos arbitrários de pontos. Para dois conjuntos de pontos, A e B , essa métrica calcula o valor mínimo da distância dos pontos em A para B e em B para A . Contudo, um ponto de ruído distante pode resultar em um aumento significativo na HaD, conforme demonstrado na Figura 7 (Veltkamp; Hagedoorn, 2001):

Figura 7 – Ilustração da distância de Hausdorff.



Fonte: Modificado de (Veltkamp; Hagedoorn, 2001).

Neste estudo, para o cálculo da HaD foi utilizada a função *HausdorffDist()*, desenvolvida para o ambiente MATLAB por Zachary Danziger (2023). A equação que rege essa função é:

$$d(A, B) = \max\{dhd(A, B), dhd(A, B)\} \quad (16)$$

em que *dhd* é a Distância Direcional de Hausdorff, que é conceituada como a máxima distância entre o ponto p pertencente ao conjunto A e o ponto mais próximo em B . Essa distância é calculada como a menor distância euclidiana entre p e qualquer ponto em B . Em termos mais simples, o *dhd* identifica o ponto em A que está mais afastado de qualquer ponto em B e mensura a distância desse ponto ao seu vizinho mais próximo em B .

2.4 Estado da Arte

Inúmeras pesquisas englobam a segmentação de estruturas de interesse em imagens mamográficas, aplicando métodos diversos como técnicas de limiarização global, algoritmos baseados em *watersheds* e métodos de contornos ativos. Embora cada uma dessas abordagens possua suas características distintas, todas enfrentam desafios apresentados por imagens

mamográficas, tais como a presença de ruídos e o baixo contraste entre as estruturas mamárias.

No estudo conduzido por Souza e Angelo (2014), os nódulos presentes em imagens mamográficas foram segmentados com o uso da abordagem de contornos ativos proposta por Kass, Witkin e Terzopoulos (1988). Três diferentes abordagens foram empregadas em 180 regiões de interesse (ROIs), por meio de uma interface gráfica desenvolvida pelos autores. Em todas elas as imagens foram submetidas à segmentação por contorno ativo. No entanto, na primeira, a segmentação foi o único procedimento aplicado. Já na segunda, também foi aplicada a técnica de filtragem com um filtro passa-baixa para suavização, enquanto na terceira e última abordagem foram utilizadas três técnicas: filtragem, binarização e equalização de imagem.

Para realizar uma comparação entre as três diferentes abordagens, os pesquisadores optaram por utilizar a metodologia das Curvas ROC, quantificando os erros em falso-negativo (FN) ou falso-positivo (FP) e os acertos em verdadeiro-positivo (VP) e verdadeiro-negativo (VN). Para isso, foi definido que, ao atingir a estabilidade em um local de mínima energia durante as iterações, o *snake* classificaria o resultado como positivo; caso contrário, seria considerado negativo.

Dessa forma, os resultados obtidos apontaram que o método de contorno ativo foi mais eficiente para segmentar nódulos precedido da etapa de filtragem, visto que os nódulos foram segmentados com 94% de VP e 5% de FP. Com um resultado relativamente próximo, a segmentação combinada com filtragem, binarização e equalização obteve 92% de VP e 7% de FP. No entanto, a aplicação da segmentação sem que antes fosse realizado algum tipo de pré-processamento apresentou o pior resultado, com taxas de 77% de VP e 22% de FP.

Em um estudo semelhante, de Marcomini, Schiabel e Verçosa (2012), a segmentação de nódulos em imagens de ultrassonografia de mama foi implementada com base na aplicação de contornos ativos. No entanto, os autores realizaram a segmentação de 50 ROIs e, em seguida, um pós-processamento, sem antes passar pela etapa de pré-processamento. No pós-processamento, foi considerado que cada ROI seria composta por apenas uma lesão, a região com maior área. Então, os pixels vizinhos conectados a essa

região foram preservados na imagem resultante e os pixels sem conexão foram removidos.

Os autores optaram por não utilizar técnicas de pré-processamento, pois, baseado em experimentos conduzidos durante o estudo, a borda da lesão mamária não era reconhecida após ser suavizada, uma vez que, na suavização, as fronteiras tendem a adquirir níveis de cinza mais homogêneos. Contudo, essa escolha acarretou em imagens resultantes com bordas irregulares e espiculadas, devido à presença de ruído. Apesar disso, as lesões mamárias foram segmentadas sem apresentar distorções em seu aspecto morfológico ou limites.

Para avaliar o desempenho desse procedimento, a área segmentada resultante foi comparada com o *ground-truth* (GT) delineado por um radiologista, classificando como VP as áreas segmentadas coincidentes com o GT; FP áreas consideradas como negativas, que não estavam presentes no GT; VN caso os pixels não fizessem parte do GT e não fossem identificadas na segmentação e, por fim, FN caso os pixels estivessem presentes, mas com segmentação incorreta. Além disso, foram utilizadas métricas como a acurácia (ACC), sensibilidade (SEN) e valor preditivo positivo (VPP). Os resultados obtidos apontaram para uma acurácia de 91,76%, SEN de 72,59% e VPP de 93,93% da segmentação, validando, assim, a utilização da segmentação de neoplasias mamárias por meio do uso de contornos ativos.

Por sua vez, Radhi e Kamil (2021) aplicaram três abordagens de contorno ativo: o método tradicional paramétrico, o método *level set* baseado em bordas e o método *level set* Chan-Vese. As imagens mamográficas originais foram pré-processadas com uma máscara Gaussiana, para remoção de ruídos, e com o método CLAHE, para realce de contraste. Após essa etapa, as imagens foram submetidas a um dos métodos de contorno ativo.

Os métodos foram testados por meio das métricas *jaccard* (Js), coeficiente de similaridade *Dice* (DSC), *PF-score* (PFs), precisão (PRE) e SEN e também por meio de uma análise das características da imagem segmentada. Os resultados indicam que a abordagem paramétrica teve uma segmentação limitada, enquanto as abordagens *level set* apresentaram um desempenho melhor. O método *level set* de Chan-Vese foi capaz de determinar a localização e forma do tumor de maneira precisa, apresentando os melhores resultados para

as métricas calculadas e, ainda, foi capaz de segmentar a maior parte dos tumores presentes nas imagens.

Além disso, uma gama de outros estudos comprovaram a eficiência dos contornos ativos como método de segmentação de lesões mamárias. A maioria desses estudos utiliza combinações de técnicas de pré-processamento anteriores à segmentação para redução de ruído e realce de contraste, como os estudos realizados por Ciecholewski (2017); Rahmati, Adler e Hamarneh (2012); Rezaee, Ahmadi e Anari (2022); Syazwani Mohd Ghani, Jumaat e Mahmud (2022).

Para uma melhor compreensão e comparação desses estudos, a Tabela 1 fornece uma visão detalhada dos conjuntos de dados usados em cada pesquisa, juntamente com as técnicas, resultados e métricas correspondentes.

Tabela 1 - Resumo dos trabalhos relacionados que utilizam de técnicas de contornos ativos (*OV*: *overlap value*, *RE*: *recall*, *ACC*: acurácia, *SEN*: sensibilidade, *VPP*: valor preditivo positivo, *Js*: *jaccard*, *DSC*: coeficiente de similaridade *Dice*, *PFs*: *PF-score*, *PRE*: precisão, *HaD*: distância de Hausdorff).

Trabalho	Dataset	Técnica(s)	Resultado(s) e métrica(s)
Ciecholewski (2017)	120 ROIs - DDSM e MIAS	<p>1 - Inversão da imagem, equalização de histograma (HE), filtragem de difusão anisotrópica (ADF) e filtragem Gaussiana + contorno ativo baseado em borda (EM)</p> <p>2 - Inversão da imagem, HE, ADF e filtragem Gaussiana + contorno ativo geométrico (GAC)</p> <p>3 - Filtragem Close-Open (CO) + contorno ativo sem borda (ACWE)</p>	<p>1 - 81% OV</p> <p>2 - 79% OV</p> <p>3 - 76% OV</p>
Marcomini, Schiabel e Verçosa (2012)	50 ROIs – Banco de dados próprio	ACM + pós-processamento	91.76% ACC, 72.59% SEN, 93.93% VPP
Radhi e Kamil (2021)	322 imagens mamográficas - mini-MIAS	<p>1 - Máscara Gaussiana + CLAHE + contorno ativo paramétrico (PACM)</p> <p>2 - Máscara Gaussiana + CLAHE + contorno ativo <i>level set</i> baseado em borda (GEACM)</p> <p>3 - Máscara Gaussiana + CLAHE + contorno ativo <i>level set</i> de Chan-veese (CVM)</p>	<p>Para massas mal definidas:</p> <p>1 - 48% Js, 65% DSC, 66% PFs, 45% PRE, 53% SEN</p> <p>2 - 68% Js, 81% DSC, 74% PFs, 79% PRE, 76% SEN</p> <p>3 - 84% Js, 91% DSC, 97% PFs, 98% PRE, 98% SEN</p>

Rahmati, Adler e Hamarneh (2012)	100 ROIs - DDSM	<p>1 - CLAHE + CVM</p> <p>2 - CLAHE + método de segmentação baseado em conjuntos de níveis adaptativos (ALSSM)</p> <p>3 - CLAHE + segmentação de espiculação usando conjuntos de níveis (SSLS)</p>	<p>1 - 86.85% ACC</p> <p>2 - 74.32% ACC</p> <p>3 - 57.11% ACC</p>
Rezaee, Ahmadi e Anari (2022)	160 imagens médicas - 80 de mamografia e 80 de ressonância magnética	<p>1 - ACM com <i>level set</i></p> <p>2 - ACM com <i>level set</i> + otimização de função</p> <p>3 - Filtro de realce de alta frequência e filtro Laplaciano + ACM com <i>level set</i> + otimização de função</p> <p>4 - Filtro de realce de alta frequência e filtro Laplaciano + ACM com <i>level set</i> + otimização de função + inicialização projetada</p>	<p>1 - 90.08% PRE, 91.16% RE, 92.72% ACC, 90.08% DSC, 44.98 HaD</p> <p>2 - 91.09% PRE, 92.64% RE, 93.29% ACC, 90.17% DSC, 36.12 HaD</p> <p>3 - 93.89% PRE, 94.12% RE, 94.11% ACC, 93.28% DSC, 28.74 HaD</p> <p>4 - 95.71% PRE, 95.60% RE, 96.25% ACC, 94.74% DSC, 22.18 HaD</p>
Souza e Angelo (2014)	180 ROIs - LAPIMO	<p>1 - ACM</p> <p>2 - Filtragem + ACM</p> <p>3 - Filtragem, HE e binarização + ACM</p>	<p>1 - 77% VP, 22% FP</p> <p>2 - 94% VP, 5% FP</p> <p>3 - 92% VP, 7% FP</p>
Syazwani Mohd Ghani, Jumaat e Mahmud (2022)	50 ROIs - INbreast	<p>1 - HE + Segmentação Seletiva <i>Primal-Dual</i> (PDSS)</p> <p>2 - Estiramento de histograma + PDSS</p> <p>3 - Equalização adaptativa de histograma + PDSS</p>	<p>1 - 80.1% Js, 88.7% DSC</p> <p>2 - 81.3% Js, 89.5% DSC</p> <p>3 - 68.6% Js, 81% DSC</p>

Fonte: A autoria própria.

Assim, conclui-se a influência das técnicas de pré-processamento aliadas ao processo de segmentação por contornos ativos de nódulos presentes em uma imagem mamográfica. Essa combinação possibilita uma detecção mais precisa das lesões mamárias, contribuindo, então, para prognósticos mais otimistas e assertivos.

3 METODOLOGIA

3.1 Banco de Imagens

Para realização dos testes e desenvolvimento do presente trabalho, foi utilizado o banco de imagens mamográficas INbreast. Dentre os repositórios mamográficos disponíveis, a escolha foi fundamentada nos seguintes critérios específicos: rotulagem do *ground-truth* (GT) e das lesões, método de aquisição de imagens, bem como o formato das mesmas, e acessibilidade (Logan *et al.*, 2023; Moreira *et al.*, 2012).

A compilação de dados do INbreast origina-se do Centro Hospitalar de São João em Portugal, na cidade de Porto, e é disponibilizada gratuitamente, mediante a assinatura de um termo de responsabilidade, em formato DICOM (*Digital Imaging and Communications in Medicine*). Esse formato assegura a padronização entre as imagens e a integridade de informações médicas. Somado a isso, o banco possui laudos feitos por radiologistas, incluindo informações como a localização e os limites da lesão (caso houver) e classificação BI-RADS (*Breast Imaging Reporting and Data System*). As patologias também são confirmadas histologicamente (Moreira *et al.*, 2012).

As 410 imagens disponibilizadas incluem casos com todos os tipos de densidade mamária. Elas foram anonimizadas e obtidas utilizando um mamógrafo digital FFDM *MammoNovation*, da fabricante *Siemens*, com resolução de contraste de 12 bits. A depender da placa de compressão utilizada, sendo esta escolhida com base no tamanho da mama da paciente, o tamanho das imagens varia entre 3328 x 4084 ou 2560 x 3328 pixels (Moreira *et al.*, 2012).

Visando executar a segmentação por contorno ativo, dentre as 410 disponíveis no INbreast foram selecionadas 47 imagens contendo nódulos. O padrão BI-RADS tem como propósito padronizar a classificação de densidade das mamas. De acordo com esse padrão, as imagens selecionadas são: 15 pertencentes ao padrão a, em que a mama é, em sua maioria, composta por tecido adiposo; 15 pertencentes ao padrão b, em que as mamas são compostas por tecido adiposo, mas também por áreas de tecido fibroglandular; 13 pertencentes ao padrão c, em que a mama é heterogeneamente densa, sendo composta majoritariamente por tecido fibroglandular; e quatro pertencentes ao padrão d, em que o tecido mamário é denso (Rodrigues, 2004).

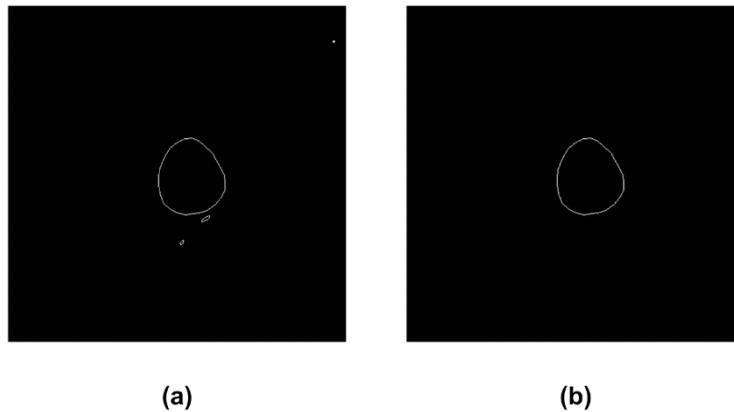
3.2 Processamento

Utilizando o *software* ImageJ, foram recortadas 53 ROIs das 47 imagens selecionadas do Inbreast. Vale ressaltar que, em alguns casos, uma única imagem continha mais de um nódulo, contribuindo para um total de ROIs superior ao número de imagens. O recorte das ROIs foi estrategicamente realizado em conformidade com o GT, cuja imagem também passou pelo processo de recorte das ROIs. Todas as ROIs resultantes foram padronizadas para o tamanho de 504 x 504 pixels, proporcionando uma base uniforme para as análises subsequentes. Essa escolha de dimensão para as ROIs foi feita devido à sua capacidade de englobar todos os nódulos identificados, sendo esse tamanho o menor tamanho possível capaz de conter todos os nódulos presentes nas imagens selecionadas.

Ainda no ImageJ, as ROIs provenientes do GT passaram por uma etapa de processamento manual que teve como foco a exclusão de microcalcificações, assegurando que as ROIs refletissem de maneira precisa apenas a presença dos nódulos de interesse, uma vez que a presença de elementos adicionais teria um impacto negativo na precisão da segmentação baseada em contorno ativo e das métricas a serem calculadas posteriormente. As microcalcificações foram removidas manualmente por meio da identificação, seleção e exclusão de todas as áreas que não faziam parte do nódulo. O INbreast contém as informações a respeito da localização das lesões mamárias, possibilitando a eliminação das

microcalcificações. Uma representação visual da remoção das microcalcificações está ilustrada da Figura 8.

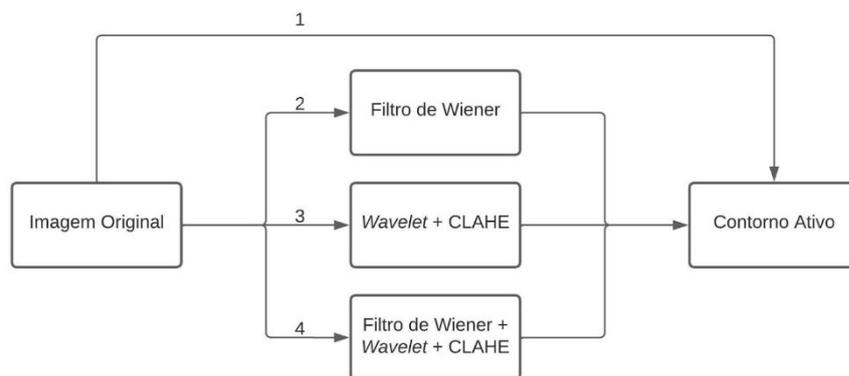
Figura 8 – ROIs do GT antes (a) e depois (b) do processamento no ImageJ, destacando apenas os nódulos de interesse após a remoção de microcalcificações.



Fonte: Autoria própria.

Posteriormente, foi desenvolvido um algoritmo no ambiente MATLAB para realizar tanto o pré-processamento quanto a segmentação por contorno ativo das imagens. Essa abordagem divide o processamento em duas fases distintas: pré-processamento e segmentação, conforme representado na Figura 9.

Figura 9 – Diagrama ilustrativo das etapas do processamento das imagens.



Fonte: Autoria própria.

Como indicado na Figura 9, cada imagem foi submetida a quatro técnicas distintas. Na primeira abordagem, a imagem original não passou por nenhum pré-processamento, sendo segmentada diretamente. Na segunda técnica, a imagem foi sujeita a um filtro de Wiener, por meio da função *wiener2()*, com uma máscara 3 x 3; seguido pela aplicação do contorno ativo. Na terceira técnica, foi utilizado um filtro de *wavelet* combinado com CLAHE com máscara 15 x 15, seguido da etapa de segmentação. Na última abordagem, a imagem passou por uma combinação de Wiener, *wavelet* e CLAHE antes de ser submetida à segmentação.

A determinação do tamanho do *kernel* do filtro de Wiener foi influenciada pelo resultado do estudo de Kannan e seus colaboradores (2016), que obtiveram como conclusão que uma janela de 3 x 3 é responsável por gerar os melhores resultados na suavização de ruídos em imagens mamográficas. Quanto ao realce de contraste, adotou-se a metodologia desenvolvida por Carneiro (2019), que envolve o emprego da técnica CLAHE com uma janela de 15 x 15 exclusivamente nos coeficientes de aproximação derivados da transformada *wavelet*.

A aplicação de um nível de decomposição da transformada *wavelet* resulta na subdivisão da imagem em quatro subimagens. Nesse processo, é essencial realizar um *thresholding* nos coeficientes, cujo valor é determinado com base na variância da imagem original e na distribuição Rayleigh. Na limiarização, os coeficientes com valores de intensidade abaixo do *thresholding* são ajustados para zero, promovendo, assim, a redução do ruído na imagem. Somado a isso, é necessário especificar a *wavelet* mãe a ser utilizada na transformada. A escolha dessa função base recaiu sobre a função *Coiflets5*, influenciada pelos resultados positivos obtidos por Costa Junior em seu estudo sobre filtragem com o uso de *wavelets* (Costa Junior, 2019).

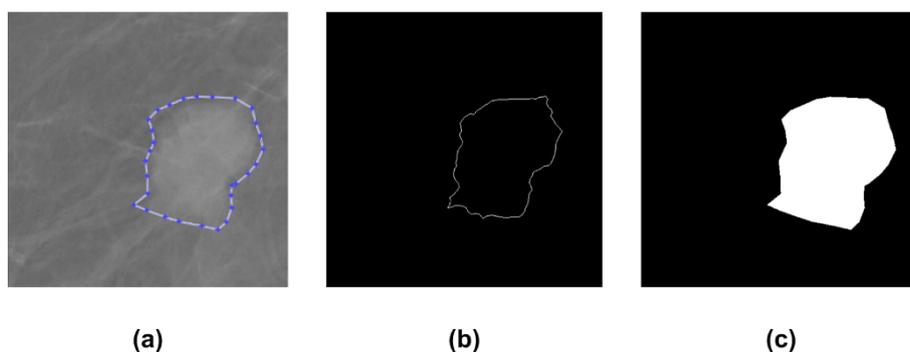
Para a aplicação da CLAHE, é preciso definir dois parâmetros adicionais: o limite de corte dos pixels, fixado em 0.01, e a função de distribuição, que, neste contexto, é uniforme. Posteriormente, deve-se realizar a transformada inversa da *wavelet*, incorporando os coeficientes de aproximação ajustados e os coeficientes originais correspondentes às direções diagonal, vertical e horizontal (Carneiro, 2019).

Resumidamente, cada uma das 53 ROIs foi aberta no algoritmo e submetida a quatro técnicas distintas de pré-processamento. Na primeira técnica, a imagem permaneceu inalterada. Na segunda técnica, aplicou-se um filtro de Wiener à imagem. Na terceira técnica, a imagem foi filtrada utilizando *wavelet* + CLAHE. Por fim, na quarta técnica, a imagem foi submetida tanto ao filtro de Wiener quanto à combinação de *wavelet* + CLAHE.

Após a etapa de pré-processamento, prosseguiu-se com a aplicação do contorno ativo, utilizando a função *activecontour()* incorporada ao MATLAB, para efetuar a segmentação dos nódulos presentes em um conjunto de 212 imagens, sendo 53 delas as ROIs originais, dando continuidade à técnica 1, e 159 as imagens geradas no pré-processamento após a aplicação do pré-processamento das técnicas 2, 3 e 4.

A definição da área da máscara de segmentação utilizada no contorno ativo foi realizada de maneira interativa empregando a função *roipoly* do MATLAB nas ROIs originais. Devido à natureza interativa, foi necessário delinear uma região distinta para cada uma das ROIs usadas. Contudo, é importante ressaltar que uma única máscara de segmentação foi aplicada em todas as quatro abordagens para uma mesma imagem. A definição da área delimitada em cada imagem foi baseada em seu respectivo GT, conforme apresentado na Figura 10.

Figura 10 – Definição interativa da área da máscara de segmentação para o contorno ativo (a) orientada pelo GT (b), gerando a máscara resultante (c).



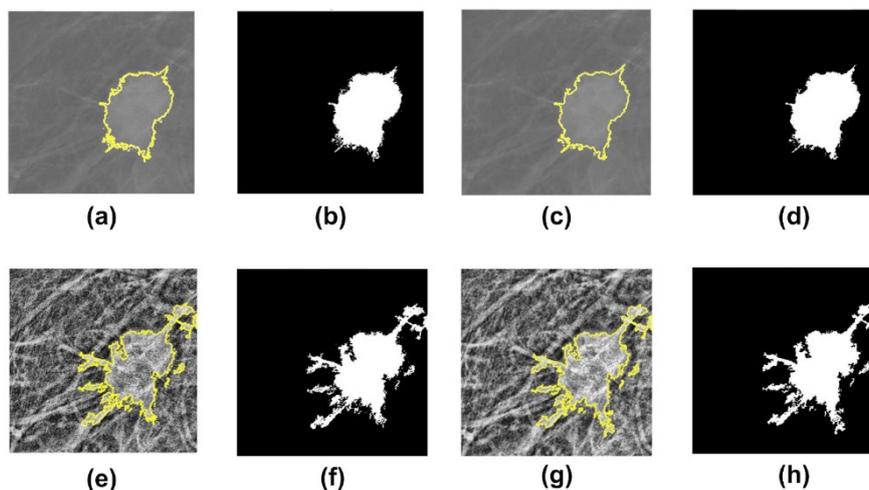
Fonte: Autoria própria.

Ao aplicar a função *roipoly*, uma ferramenta interativa de polígono é estabelecida na última imagem exibida no algoritmo. Neste trabalho, a *roipoly* foi aplicada na ROI original, como ilustrado na Figura 10 (a). Assim, é aberta uma janela no MATLAB para que seja realizada a delimitação da área de interesse na imagem. Em seguida, a função produz uma máscara como uma imagem binária, como a máscara exibida na Figura 10 (c), em que os pixels dentro da região traçada são atribuídos ao valor um e os pixels restantes ao valor zero.

Essa técnica foi adotada em virtude da diversidade nas características dos nódulos presentes em cada imagem, com variações significativas em localização e tamanho. Diante dessa heterogeneidade, a opção por traçar manualmente a região a ser segmentada em cada imagem permite uma adaptação mais precisa e personalizada às características específicas de cada nódulo. Essa estratégia interativa foi implementada com o intuito de aprimorar a eficácia da segmentação, considerando a complexidade dos padrões nodulares encontrados nas imagens analisadas.

Por fim, procedeu-se à obtenção das lesões isoladas e da sobreposição do traçado do contorno da segmentação na imagem resultante de cada uma das técnicas de pré-processamento utilizadas, conforme demonstrado na Figura 11:

Figura 11 – Exemplo da segmentação. (a) Traçado da segmentação na imagem original; (b) Lesão isolada com a técnica 1; (c) Traçado da segmentação na imagem pré-processada com a técnica 2; (d) Lesão isolada com a técnica 2; (e) Traçado da segmentação na imagem pré-processada com a técnica 3; (f) Lesão isolada com a técnica 3; (g) Traçado da segmentação na imagem pré-processada com a técnica 4; (h) Lesão isolada com a técnica 4.



Fonte: Autoria própria.

Tanto as lesões segmentadas quanto os contornos delineados foram manualmente salvos como imagens individuais. Esse estágio representa a última fase do processamento, onde as informações obtidas durante a segmentação são aplicadas às imagens originais, proporcionando uma visualização clara e destacada das regiões identificadas.

Sendo assim, de modo resumido, na segunda fase do processamento foi realizada a segmentação dos nódulos presentes em um grupo de 212 imagens, constituído por 53 ROIs originais e 159 ROIs originadas do pré-processamento. A segmentação foi conduzida mediante a utilização do método de contorno ativo, no qual a definição da máscara de segmentação foi realizada manualmente para cada ROI original, orientada pelo GT, e aplicada de maneira uniforme às quatro diferentes abordagens para uma mesma imagem. As imagens resultantes da segunda fase, exemplificadas na Figura 11, foram individualmente salvas após o processo.

3.3 Métricas

Um segundo algoritmo foi desenvolvido também no MATLAB, destinado ao cálculo das métricas: excentricidade, distância de Hausdorff e a quantidade de pixels brancos presentes nas imagens. Essas métricas foram calculadas com o intuito de possibilitar a quantificação e comparação objetiva da qualidade das segmentações realizadas.

A seleção das métricas foi baseada nas seguintes razões: a excentricidade, ao avaliar a circularidade do objeto, ajuda a identificar se a segmentação preservou o formato original do nódulo em comparação com o padrão-ouro; a distância de Hausdorff, como indicador de precisão, revela a proximidade entre o contorno segmentado do nódulo e o contorno do GT; já a quantidade de pixels brancos indica variações no tamanho do nódulo segmentado. Essas métricas, em conjunto, permitem uma avaliação completa da segmentação dos nódulos, abordando aspectos como forma, precisão e tamanho.

Cada imagem contendo as lesões isoladas por meio da segmentação, gerada por suas respectivas técnicas, foi submetida ao cálculo das métricas.

Além disso, as 53 imagens do GT também foram incluídas no cálculo das métricas para servirem como referência, ou seja, como o padrão-ouro. Ao todo, portanto, os cálculos das métricas foram realizados para um conjunto de 265 imagens.

Entretanto, as 212 imagens que continham as lesões segmentadas perderam a padronização de tamanho previamente estabelecida de 504 x 504 pixels. Esse desvio ocorreu porque as imagens foram armazenadas juntamente com legendas identificadoras, dentro das janelas plotadas pelo MATLAB. Conseqüentemente, antes de serem submetidas ao algoritmo de cálculo das métricas, todas as imagens foram cortadas com a função *crop* no ImageJ para atender aos requisitos de tamanho estabelecidos.

Inicialmente, as imagens passaram por um processo prévio de binarização, resultando em uma representação simplificada em preto e branco da lesão isolada por meio de cada técnica. Da mesma forma, a imagem GT também foi binarizada. No entanto, ela foi preenchida usando a função *imfill()* do MATLAB. Esse preenchimento teve como objetivo facilitar a análise visual e fornecer uma base sólida para o cálculo das métricas, principalmente para a quantidade de pixels brancos. A Figura 12 demonstra uma imagem GT preenchida.

Figura 12 – Imagens contendo ROIs do GT antes (a) e depois (b) do processo de preenchimento no MATLAB.



Fonte: Autoria própria.

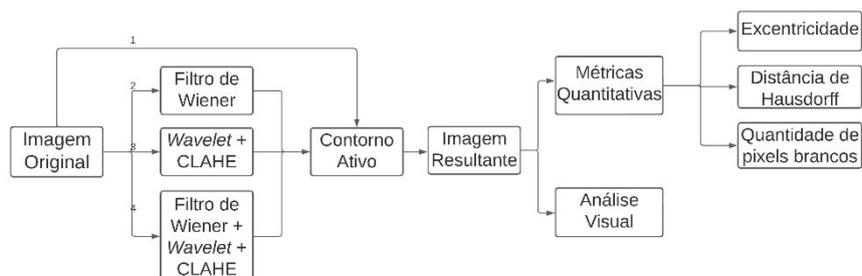
Os resultados de cada métrica para todas as imagens foram organizados em uma planilha. Nessa planilha, foram calculados a média e desvio padrão dos resultados obtidos para cada uma das quatro técnicas de processamento e da imagem GT, possibilitando, assim, que fosse realizada uma análise estatística comparativa entre as imagens. A média e o desvio padrão foram obtidos somando todos os valores obtidos dentro de cada métrica, para cada uma das técnicas, e então essa soma foi dividida pela quantidade de ROIs, que são 53.

De maneira sucinta, um conjunto de 212 imagens das lesões isoladas pela segmentação foram cortadas no ImageJ, no tamanho padrão de 504 x 504 pixels. Em seguida, juntamente com as 53 imagens do GT, todas as imagens foram abertas e binarizadas no algoritmo no MATLAB. As imagens do GT foram preenchidas e, então, todas as imagens foram submetidas ao cálculo de três métricas: a excentricidade, a distância de Hausdorff e a quantidade de pixels brancos. Enfim, os valores resultantes foram dispostos em uma planilha, onde tiveram a média e o desvio padrão calculados.

Finalmente, após o cálculo das métricas, foi conduzida uma avaliação visual das imagens para identificar as disparidades entre os métodos de processamento empregados. Essa análise permite uma compreensão mais abrangente das nuances visuais resultantes de cada abordagem e auxilia na interpretação dos resultados quantitativos obtidos por meio das métricas calculadas, contribuindo para uma avaliação mais completa das técnicas utilizadas neste estudo.

A Figura 13 resume todos os passos realizados na metodologia, desde o processamento até o cálculo das métricas e a análise visual:

Figura 13 – Resumo da metodologia.



Fonte: Autoria própria.

4 RESULTADOS E DISCUSSÕES

Na primeira etapa do processamento, o pré-processamento resultou em um total de 159 imagens. Dessas, 53 imagens foram pré-processadas de acordo com a técnica 2, 53 imagens com a técnica 3 e 53 imagens com a técnica 4. Posteriormente, na etapa de segmentação, a segunda e última parte do processamento, foram geradas 424 imagens, sendo 212 delas imagens contendo as lesões segmentadas e 212 imagens contendo a sobreposição do traçado da segmentação na imagem pré-processada e, no caso da técnica 1, na imagem original. A Tabela 2 demonstra o processamento (incluindo pré-processamento e segmentação) empregado para cada técnica.

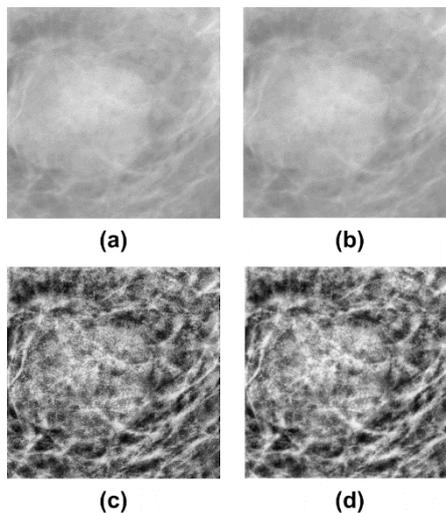
Tabela 2 - Processamento utilizado para cada técnica.

Técnica	Processamento	
	Pré-processamento	Segmentação
1	-	Contorno Ativo
2	Filtro de Wiener	Contorno Ativo
3	<i>Wavelet</i> + CLAHE	Contorno Ativo
4	Filtro de Wiener + <i>Wavelet</i> + CLAHE	Contorno Ativo

Fonte: Autoria Própria.

As imagens resultantes da fase inicial do processamento, obtidas mediante a aplicação dos métodos de pré-processamento listados na Tabela 2, estão exemplificadas na Figura 14.

Figura 14 – Imagens resultantes após a aplicação dos pré-processamentos. (a) Imagem Original; (b) Filtro de Wiener; (c) *Wavelet* + CLAHE; (d) Filtro de Wiener + *Wavelet* + CLAHE.



Fonte: Autoria Própria.

Percebe-se que a imagem pré-processada com a técnica 2 na Figura 14 (b) pouco se difere visualmente da imagem original na Figura 43 (a). Da mesma forma, as imagens (c) e (d) apresentam uma baixa diferença visual entre si. Isso ocorre porque a suavização de ruído realizada pelo filtro de Wiener com máscara de 3×3 é limitada a uma área reduzida ao redor de cada pixel, considerando o tamanho total da imagem (504×504 pixels). Assim, as mudanças apresentadas na imagem, como o borramento, são sutis e não podem ser avaliadas somente por meio da análise visual, necessitando também de uma análise quantitativa.

Além disso, é possível perceber que, na Figura 14 (c) e (d), as estruturas presentes na mama possuem maior realce quando comparadas com a imagem original na Figura 14 (a), em decorrência do realce de contraste realizado com a aplicação da técnica CLAHE com uma janela de tamanho 15×15 somente nos coeficientes de aproximação derivados da transformada *wavelet*.

4.1 Resultados Quantitativos e Discussões

4.1.1 Excentricidade

A excentricidade quantifica a circularidade de um objeto. A Tabela 3 mostra os resultados obtidos para a média e desvio padrão da excentricidade

calculada para os GTs e para as imagens binárias das lesões segmentadas pelos métodos de processamento utilizados. Destaca-se que a excentricidade do GT é o padrão-ouro. Quanto mais o valor obtido se aproximar desse padrão, maior será a fidelidade da segmentação à preservação do formato original.

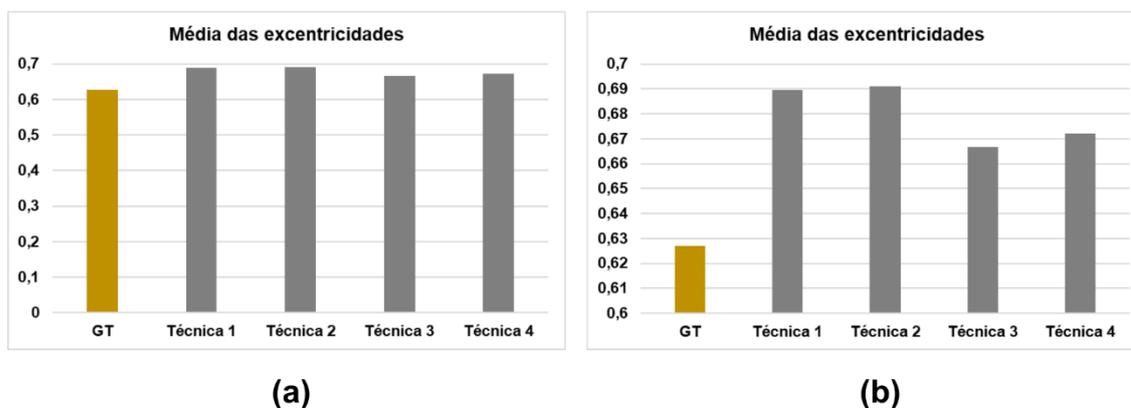
Tabela 3 - Valores médios da excentricidade e seus respectivos desvios padrões calculados para o GT e cada uma das técnicas utilizadas no processamento.

Métrica	Excentricidade				
	<i>Ground-Truth</i>	Técnica 1 - Contorno Ativo	Técnica 2 - Filtro de Wiener + Contorno Ativo	Técnica 3 - <i>Wavelet</i> + CLAHE + Contorno Ativo	Técnica 4 - Filtro de Wiener + <i>Wavelet</i> + CLAHE + Contorno Ativo
Média	0,6268	0,6896	0,6910	0,6666	0,6721
Desvio Padrão	0,1581	0,1606	0,1683	0,1823	0,1820

Fonte: Autoria Própria.

Para a excentricidade, os valores que mais se aproximam do valor médio do GT, que é de 0,6268, são os seguintes: 0,6666 (Técnica 3); 0,6721 (Técnica 4); 0,6896 (Técnica 1); e 0,6910 (Técnica 2). Os gráficos na Figura 15 proporcionam uma melhor compreensão destes dados.

Figura 15 - Gráficos ilustrando as médias das excentricidades calculadas em diferentes escalas. Em (a) o gráfico possui escala com menor variação, enquanto em (b) a escala apresenta maior variação.



Fonte: Autoria Própria.

O gráfico da Figura 15 (a) destaca que os valores obtidos são bastante próximos entre si. Contudo, para evidenciar a discrepância nas médias das excentricidades, o gráfico da Figura 15 (b) possui uma escala mais detalhada, na qual é possível observar de forma mais minuciosa a variação dos resultados.

Embora capazes de identificar as áreas lesionadas, observou-se visualmente que os quatro métodos utilizados enfrentam problemas de supersegmentação, abrangendo áreas além do nódulo, ou restringindo o contorno ativo, resultando na exclusão de partes do nódulo. Em decorrência desses problemas, os nódulos segmentados apresentam, em sua maioria, formatos irregulares.

Os resultados, tanto na Tabela 3 quanto na Figura 15, evidenciam que essa questão impacta significativamente o formato da lesão segmentada, levando a formas mais elípticas no geral. Mesmo a técnica 3, com uma média de excentricidade mais próxima ao GT, ainda apresenta uma diferença considerável nesse aspecto.

Além disso, percebe-se que as técnicas que utilizam filtro de Wiener apresentaram valores maiores para a excentricidade quando comparadas às técnicas que não o utilizam. É interessante notar que essa distância na excentricidade causada pelo filtro de Wiener foi observada tanto na técnica 2, em comparação com a técnica 1, quanto na técnica 4 em relação à técnica 3.

4.1.2 Distância de Hausdorff

A distância de Hausdorff mensura a similaridade entre dois conjuntos de pontos considerando as distâncias entre eles. Assim, o valor zero indica dois conjuntos perfeitamente correspondentes. A Tabela 4 exhibe os resultados obtidos para a média e desvio padrão da HaD calculada, em relação ao GT, para as imagens binárias das lesões segmentadas por cada uma das técnicas empregadas no processamento. No entanto, é importante mencionar que não existem valores de HaD para o GT, já que a comparação está sendo feita em relação ao próprio padrão-ouro estabelecido pelos GTs.

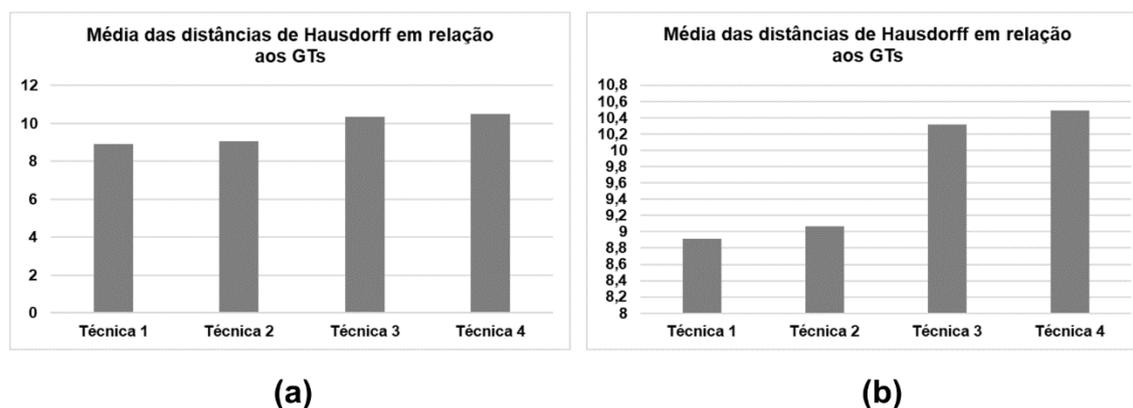
Tabela 4 - Valores médios da distância de Hausdorff e seus respectivos desvios padrões calculados para cada uma das técnicas utilizadas no processamento.

Métrica	Distância de Hausdorff em relação ao GT			
	Técnica 1 - Contorno Ativo	Técnica 2 - Filtro de Wiener + Contorno Ativo	Técnica 3 - Wavelet + CLAHE + Contorno Ativo	Técnica 4 - Filtro de Wiener + Wavelet + CLAHE + Contorno Ativo
Média	8,9148	9,0694	10,3214	10,4926
Desvio Padrão	1,9384	2,0399	1,7373	1,7444

Fonte: Autoria Própria.

Por sua vez, para a distância de Hausdorff, os valores médios listados são os seguintes: 8,9148 (Técnica 1); 9,0694 (Técnica 2); 10,3214 (Técnica 3); e 10,4926 (Técnica 4). É possível ter uma visão mais clara desses resultados por meio dos gráficos apresentados, em diferentes escalas, na Figura 16.

Figura 16 - Gráficos ilustrando as médias das distâncias de Hausdorff em relação aos GTs calculadas em diferentes escalas. Em (a) o gráfico possui escala com menor variação, enquanto em (b) a escala apresenta maior variação.



Fonte: Autoria Própria.

O gráfico da Figura 16 (a) indica uma proximidade considerável entre os valores obtidos. No entanto, para enfatizar a discrepância nas médias das distâncias de Hausdorff calculadas, o gráfico correspondente na Figura 16 (b) adota uma escala mais precisa.

As técnicas 3 e 4 exibiram as maiores distâncias de Hausdorff calculadas. Isso pode ser atribuído à sensibilidade desta métrica a divergências na forma do nódulo em comparação com o GT. A ocorrência de supersegmentação, que resulta em pontos distantes do contorno, contribui significativamente para o aumento da Distância de Hausdorff, assim como contornos discrepantes também influenciam diretamente essa métrica.

Ao aplicarem o realce de contraste, as técnicas 3 e 4 podem levar a segmentação a reconhecer pontos distantes com intensidade similar à do nódulo como parte do nódulo, levando a um aumento na distância de Hausdorff em relação ao GT. Essa observação permanece válida mesmo em mamas densas, onde os resultados dessas técnicas são considerados mais satisfatórios, uma vez que as bordas apresentadas são irregulares e supersegmentadas.

Por fim, observa-se que a técnica 1 apresentou a menor HaD calculada, sugerindo que a segmentação por contorno ativo sem qualquer pré-processamento exibiu maior proximidade com o resultado esperado do GT, ainda que diferente de zero. Além disso, observa-se que as técnicas que incorporam o filtro de Wiener exibiram valores mais elevados para a HaD.

4.1.3 Quantidade de pixels brancos presentes nas imagens

Na Tabela 5 são apresentados os resultados obtidos para a média e desvio padrão da quantidade de pixels brancos presentes nas imagens, tanto nos GTs quanto nas imagens binárias das lesões segmentadas por cada um dos métodos de processamento. Após a binarização das imagens, a área segmentada é representada na cor branca, permitindo a contagem dos pixels brancos que correspondem à região do nódulo.

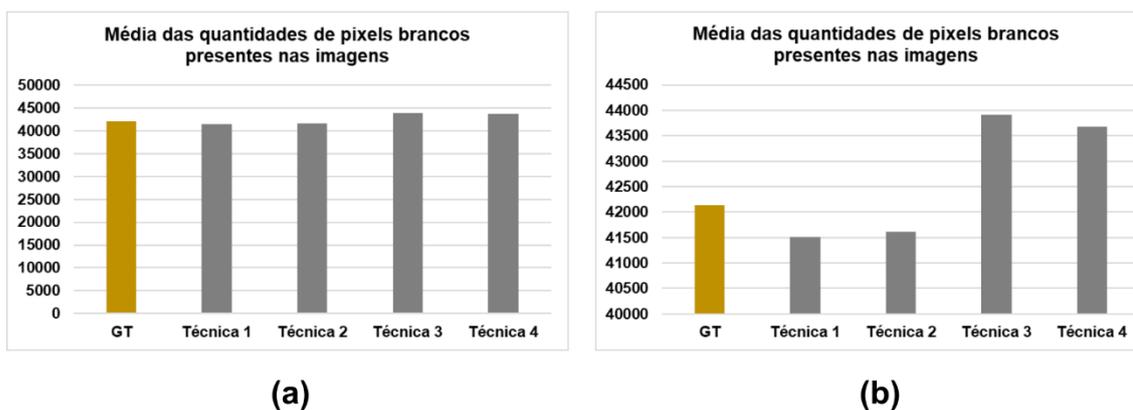
Tabela 5 - Valores médios da quantidade de pixels brancos presentes nas imagens e seus respectivos desvios padrões calculados para o GT e cada uma das técnicas utilizadas no processamento.

Métrica	Quantidade de pixels brancos presentes nas imagens				
	<i>Ground-truth</i>	Técnica 1 - Contorno Ativo	Técnica 2 - Filtro de Wiener + Contorno Ativo	Técnica 3 - <i>Wavelet</i> + CLAHE + Contorno Ativo	Técnica 4 - Filtro de Wiener + <i>Wavelet</i> + CLAHE + Contorno Ativo
Média	42130,10	41516,92	41605,60	43920,35	43677,71
Desvio Padrão	36349,00	31678,27	31556,30	35029,34	34492,92

Fonte: Autoria Própria.

Os valores médios para a quantidade de pixels brancos presentes nas imagens mais próximos do GT, que possui média de 42130,10, são: 41605,60 (Técnica 2); 41516,92 (Técnica 1); 43677,71 (Técnica 4); e 43920,35 (Técnica 3). As representações gráficas na Figura 17 oferecem uma forma mais clara de visualizar esses valores, por meio de diferentes escalas.

Figura 17 - Gráficos ilustrando as médias das quantidades de pixels brancos presentes nas imagens calculadas em diferentes escalas. Em (a) o gráfico possui escala com menor variação, enquanto em (b) a escala apresenta maior variação.



Fonte: Autoria Própria.

O gráfico da Figura 17 (a) mostra uma semelhança notável nos valores obtidos. Porém, para destacar a disparidade nas médias das quantidades de pixels brancos presentes nas imagens, o gráfico representado na Figura 17 (b) adota uma escala mais refinada.

É importante destacar que a quantidade de pixels brancos isoladamente não oferece conclusões definitivas sobre a qualidade da segmentação. Mesmo que duas imagens possuam a mesma quantidade de pixels brancos ou quantidades similares, suas características podem ser completamente distintas. Portanto, essa métrica foi especialmente útil para diferenciar a qualidade de segmentações em técnicas muito próximas entre si, como é o caso das técnicas 1-2 e 3-4.

Fatores como tamanho, formato e pré-processamento influenciam a quantidade de pixels brancos em uma imagem. Por exemplo, a técnica de realce de contraste impacta a distribuição dos tons de cinza na imagem, resultando em uma segmentação diferenciada. Essa modificação na segmentação influencia diretamente na fase de binarização, alterando a região segmentada e, conseqüentemente, a contagem de pixels brancos. A variação na distribuição de tons de cinza modifica a forma como a imagem é posteriormente transformada em binária, o que influencia diretamente na quantidade de pixels brancos contabilizados na região do nódulo. As técnicas 3 e 4 apresentam valores médios mais elevados devido a essas alterações.

Em uma análise geral, a técnica 2 apresentou uma quantidade de pixels mais próxima ao GT do que a técnica 1. Similarmente, a técnica 4 demonstrou uma segmentação mais próxima ao GT do que a técnica 3. Assim, percebe-se que o filtro de Wiener, apesar de não apresentar diferenças visuais substanciais nas imagens, exibe diferenças que são refletidas na contagem dos pixels brancos. Isso se deve à atenuação de ruído realizada pelo filtro, a qual influencia o reconhecimento das bordas do nódulo, possivelmente afetando a contagem dos pixels brancos.

Portanto, os resultados obtidos revelam que as técnicas 1 e 2 tendem a reduzir a área segmentada pelo contorno ativo, enquanto as técnicas 3 e 4 sugerem uma propensão à supersegmentação dos nódulos presentes nas imagens analisadas.

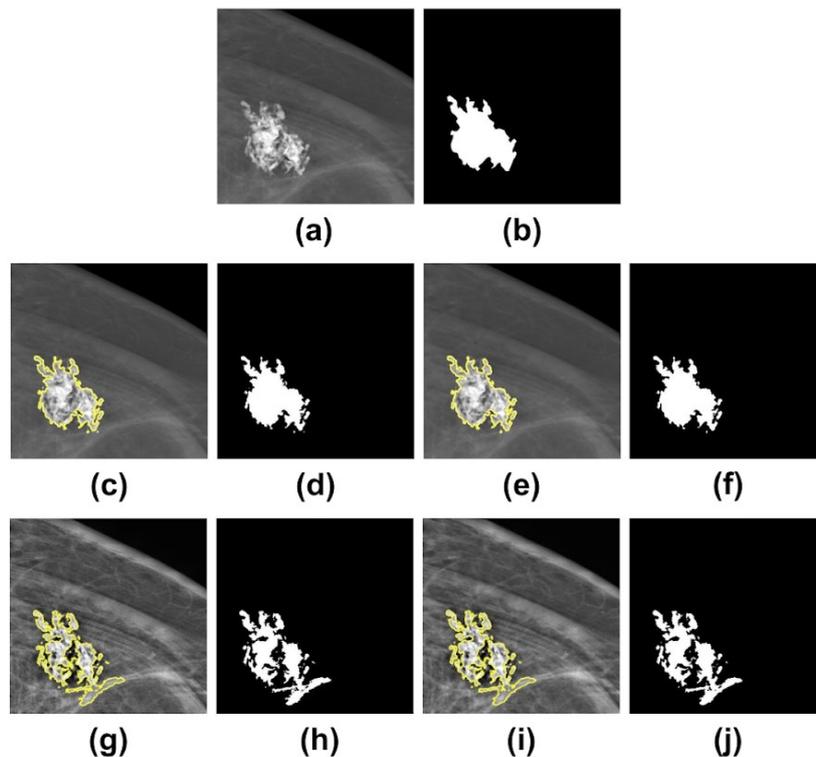
A técnica de contorno ativo segmenta a imagem por meio de um processo iterativo de crescimento de região a partir de uma curva inicial, a máscara de segmentação. Uma vez que a função *roipoly()* utilizada gera um polígono preenchido em uma imagem binária como máscara, os resultados de sub ou supersegmentação não são provenientes de buracos na máscara. Entretanto,

dado que o contorno ativo do MATLAB se ajusta às características da imagem, o uso de um polígono pode não ser tão apropriado para segmentar lesões circulares ou elípticas, que possuem contornos mais suaves ou complexos. Nesses casos específicos, o polígono pode resultar em uma segmentação imprecisa.

4.2 Resultados Qualitativos - Análise visual

Após a conclusão da segmentação, as bordas do contorno ativo foram sobrepostas nas imagens resultantes do pré-processamento para cada uma das abordagens utilizadas. Somado a isso, foram obtidas imagens contendo somente as lesões segmentadas. As Figuras 18, 19, 20 e 21 exemplificam os resultados obtidos nessa etapa.

Figura 18 - Resultados gerados por meio da segmentação das imagens. (a) Imagem Original; (b) GT binarizado e preenchido da imagem original; (c) Imagem original sobreposta com o contorno ativo (técnica 1); (d) ROI binarizada após a segmentação com a técnica 1; (e) Imagem pré-processada com filtro de Wiener sobreposta com o contorno ativo (técnica 2); (f) ROI binarizada após a segmentação com a técnica 2; (g) Imagem pré-processada com *Wavelet* + CLAHE sobreposta com o contorno ativo (técnica 3); (h) ROI binarizada após a segmentação com a técnica 3; (i) Imagem pré-processada com Filtro de Wiener + *Wavelet* + CLAHE sobreposta com o contorno ativo (técnica 4); (j) ROI binarizada após a segmentação com a técnica 4.



Fonte: Autoria Própria.

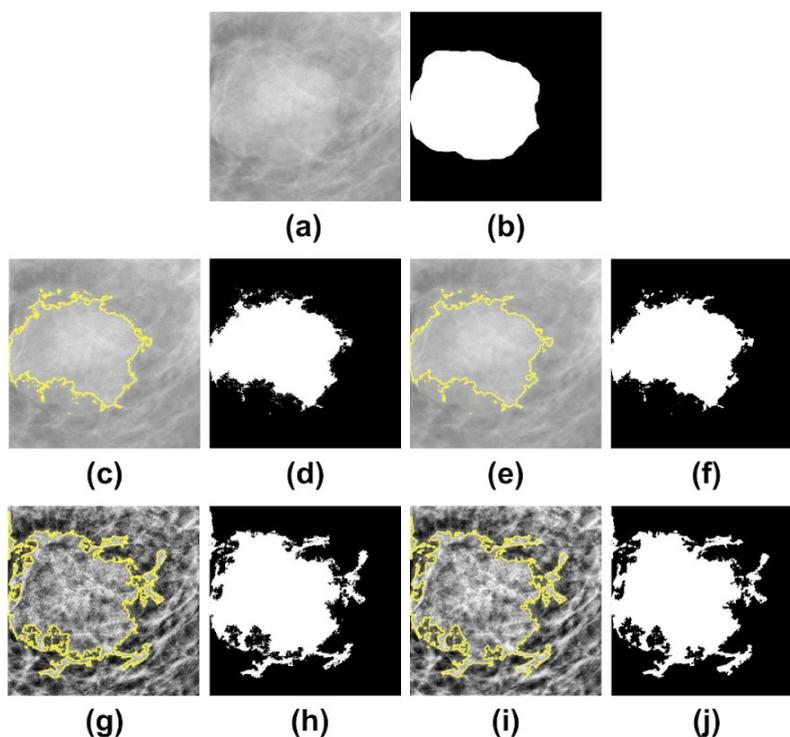
Na Figura 18, percebe-se que as imagens (h) e (j) apresentam maior diferença entre as áreas segmentadas e o GT na ROI (b). Esse fenômeno é atribuído ao realce de contraste, o qual realça não apenas o nódulo, mas todas as estruturas presentes na imagem, incluindo estruturas e tecidos adjacentes que não fazem parte da porção do nódulo. A proximidade dessas estruturas e tecidos ao nódulo causa uma imprecisão no contorno ativo, ocasionando a incorporação dessas regiões na área segmentada. Tal fenômeno, conhecido como supersegmentação, culmina na delimitação de áreas segmentadas superiores às dimensões reais dos nódulos.

Adicionalmente, é possível que o contorno ativo não identifique as regiões mais escuras do nódulo, compostas por pixels de menor intensidade, como

constituintes efetivas do mesmo, especialmente após o realce de contraste. Isso pode ocasionar lacunas ou áreas não preenchidas nas imagens segmentadas, onde se esperava que houvesse uma continuidade no preenchimento do nódulo.

Ainda na Figura 18, as ROIs (d) e (f) exibem a maior similaridade com o GT na Figura 18 (b), indicando que as técnicas 1 e 2 demonstram uma segmentação mais precisa do nódulo presente na imagem, cuja mama pertence ao padrão b. Esses resultados não são exclusivos dessa imagem, sendo observados na maior parte das imagens pertencentes aos padrões a e b de densidade mamária. Assim, evidencia-se que as técnicas 1 e 2 se destacam na segmentação de nódulos presentes em mamas menos densas e com menor presença de tecido fibroglandular.

Figura 19 - Resultados gerados por meio da segmentação das imagens. (a) Imagem Original; (b) GT binarizado e preenchido da imagem original; (c) Imagem original sobreposta com o contorno ativo (técnica 1); (d) ROI binarizada após a segmentação com a técnica 1; (e) Imagem pré-processada com filtro de Wiener sobreposta com o contorno ativo (técnica 2); (f) ROI binarizada após a segmentação com a técnica 2; (g) Imagem pré-processada com *Wavelet* + CLAHE sobreposta com o contorno ativo (técnica 3); (h) ROI binarizada após a segmentação com a técnica 3; (i) Imagem pré-processada com Filtro de Wiener + *Wavelet* + CLAHE sobreposta com o contorno ativo (técnica 4); (j) ROI binarizada após a segmentação com a técnica 4.



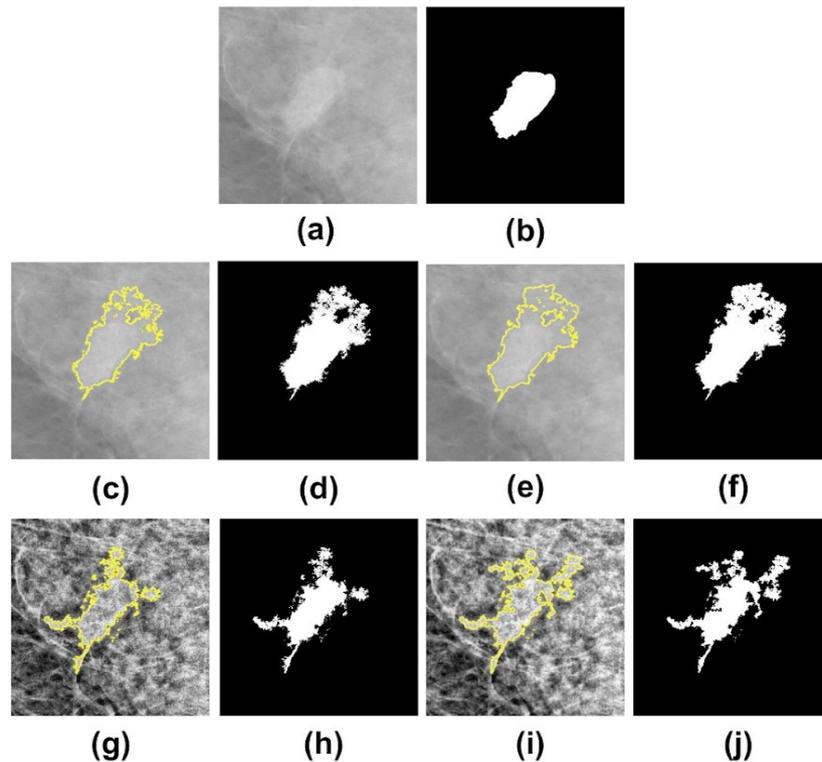
Fonte: Autoria Própria.

Já na Figura 19, a imagem da mama analisada pertence ao padrão d de densidade mamária, caracterizada como uma mama densa. Nas técnicas 1 e 2, o contorno ativo resultou em uma subsegmentação do nódulo. Ou seja, a segmentação não incluiu completamente o nódulo, indicando que ela encolheu. Nesse contexto, em mamas densas, o tecido fibroglandular se assemelha muito ao nódulo, levando o contorno ativo a excluir partes que, na verdade, pertencem ao nódulo. Esse comportamento é evidenciado pela comparação visual das imagens (d) e (f) com o GT na imagem (b) da Figura 19.

Por outro lado, nas técnicas 3 e 4, apesar de segmentarem estruturas não pertencentes ao nódulo, o formato real do nódulo foi melhor preservado. Essa observação torna-se clara ao comparar visualmente as ROIs (h) e (j) com o GT na Figura 19 (b). Esses mesmos resultados são notáveis em grande parte das imagens pertencentes ao padrão c e d.

Para mamas densas, pertencentes ao padrão BI-RADS d, em que a limitação da mamografia é maior devido à semelhança entre a atenuação de raios X do tecido fibroglandular e dos nódulos mamários, o realce de contraste permite uma visualização mais clara das estruturas. Nesse contexto, a capacidade das técnicas que utilizam realce de contraste em manter a forma do nódulo destaca a complexidade da segmentação em mamas densas e a importância de técnicas que consigam distinguir adequadamente entre o tecido fibroglandular e o nódulo para uma segmentação mais precisa.

Figura 20 - Resultados gerados por meio da segmentação das imagens. (a) Imagem Original; (b) GT binarizado e preenchido da imagem original; (c) Imagem original sobreposta com o contorno ativo (técnica 1); (d) ROI binarizada após a segmentação com a técnica 1; (e) Imagem pré-processada com filtro de Wiener sobreposta com o contorno ativo (técnica 2); (f) ROI binarizada após a segmentação com a técnica 2; (g) Imagem pré-processada com *Wavelet* + CLAHE sobreposta com o contorno ativo (técnica 3); (h) ROI binarizada após a segmentação com a técnica 3; (i) Imagem pré-processada com Filtro de Wiener + *Wavelet* + CLAHE sobreposta com o contorno ativo (técnica 4); (j) ROI binarizada após a segmentação com a técnica 4.



Fonte: Autoria Própria.

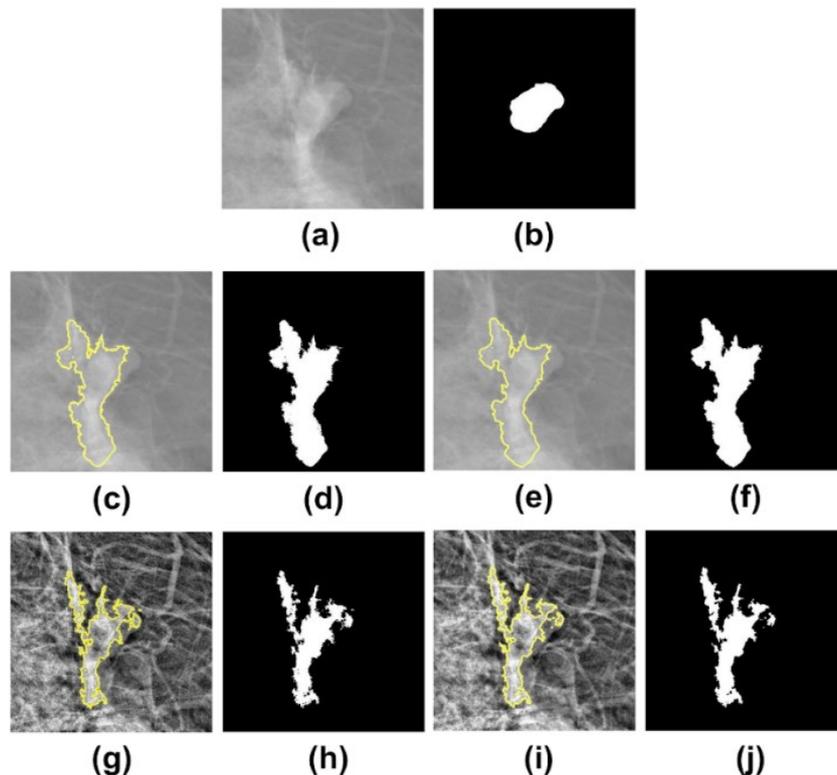
Na Figura 20 (a), a ROI original foi extraída de uma imagem mamográfica que se enquadra no padrão c de densidade mamária. A avaliação visual das técnicas empregadas revela que todas as abordagens utilizadas apresentaram supersegmentação do nódulo, desviando-se do GT exibido na Figura 20 (b), como ilustrado nas Figuras 20 (d), (f), (h) e (j).

No entanto, é possível perceber que as técnicas 2 e 4, que utilizam o filtro de Wiener no pré-processamento, identificaram um número superior de regiões em comparação com as técnicas 1 e 3, respectivamente, que não fazem uso desse filtro.

Então, ao analisar especificamente as técnicas 1 e 3, observa-se que a técnica 3, que combina a utilização de *wavelet* com CLAHE, se destacou ao

proporcionar uma segmentação visualmente mais eficiente do nódulo. Esta técnica foi capaz de isolar o nódulo de maneira mais precisa em relação a outras estruturas semelhantes presentes na imagem, contribuindo para uma visualização mais nítida e específica do nódulo em questão.

Figura 21 - Resultados gerados por meio da segmentação das imagens. (a) Imagem Original; (b) GT binarizado e preenchido da imagem original; (c) Imagem original sobreposta com o contorno ativo (técnica 1); (d) ROI binarizada após a segmentação com a técnica 1; (e) Imagem pré-processada com filtro de Wiener sobreposta com o contorno ativo (técnica 2); (f) ROI binarizada após a segmentação com a técnica 2; (g) Imagem pré-processada com *Wavelet* + CLAHE sobreposta com o contorno ativo (técnica 3); (h) ROI binarizada após a segmentação com a técnica 3; (i) Imagem pré-processada com Filtro de Wiener + *Wavelet* + CLAHE sobreposta com o contorno ativo (técnica 4); (j) ROI binarizada após a segmentação com a técnica 4.



Fonte: Autoria Própria.

Na Figura 21, observa-se que nenhuma das técnicas aplicadas conseguiu segmentar o nódulo de maneira eficaz nessa imagem correspondente ao padrão c de densidade mamária. Esse resultado se deve à presença de áreas adjacentes ao nódulo com pixels de intensidade semelhantes aos do próprio nódulo. Isso resultou no contorno ativo excedendo a área que deveria ter sido segmentada para todas as técnicas utilizadas.

No entanto, entre as técnicas aplicadas, as técnicas 3 e 4, ilustradas na Figura 21 (h) e (j), respectivamente, proporcionaram uma segmentação relativamente melhor quando comparadas ao GT na Figura 21 (b), embora ainda não tenham alcançado uma segmentação ideal.

Esses resultados ressaltam a dificuldade do contorno ativo em distinguir corretamente as áreas que compõem o nódulo de outras estruturas com intensidades de pixel semelhantes, o que, em alguns casos, compromete a segmentação precisa das áreas de interesse.

4.3 Comparação entre Resultados Qualitativos e Quantitativos e Discussões

Os resultados qualitativos, obtidos por meio de uma análise visual, sugerem que a eficácia das abordagens está associada à natureza da densidade mamária. Em particular, para mamas classificadas nos padrões de densidade mamária c e d, observou-se uma maior eficácia das técnicas que empregam realce de contraste (técnicas 3 e 4) na segmentação das estruturas. Em contrapartida, para mamas menos densas (maior presença de tecido adiposo), enquadradas nos padrões a e b do BI-RADS, constatou-se que essas mesmas técnicas tendem a resultar em supersegmentação, ultrapassando a delimitação desejada do nódulo. Neste contexto, as técnicas 1 e 2 demonstraram-se mais eficazes na segmentação, ressaltando uma melhor adequação para mamas menos densas.

Dada a limitação da análise visual na determinação precisa da técnica de segmentação mais eficaz, a adoção de métricas quantitativas tornou-se essencial para a avaliação comparativa do desempenho das abordagens empregadas. A análise quantitativa revelou que, para mamas com maior densidade, a técnica 3 apresentou o desempenho mais proeminente. Em contrapartida, para mamas caracterizadas por uma menor presença de tecido fibroglandular, a técnica 1 demonstrou uma performance superior.

A aplicação do contorno ativo sem pré-processamento, na técnica 1, apresentou resultados satisfatórios tanto na análise qualitativa quanto na quantitativa. Vale lembrar que a segmentação foi realizada em uma ROI de tamanho 504 x 504, a qual foi recortada da imagem original e delimitada a partir

da localização precisa do nódulo mamário conforme indicado pelo GT. É importante ponderar que, se o nódulo tivesse sido identificado na imagem original como um todo, e não em uma ROI, os resultados poderiam divergir, destacando possíveis variações nos efeitos e na eficácia da etapa de pré-processamento.

Além disso, percebe-se que o filtro de Wiener apresentou maiores alterações nas métricas de excentricidade e distância de Hausdorff. Apesar disso, a suavização de ruído proporcionada por esse filtro forneceu resultados mais próximos do padrão GT para a quantidade de pixels brancos. Por sua vez, o realce de contraste apresentou os melhores resultados para a excentricidade, destacando que, com o realce de contraste, os nódulos tiveram seu formato original mais preservados após o processamento. Entretanto, os processamentos que envolvem o realce de contraste obtiveram resultados mais distantes do GT para a distância de Hausdorff e quantidade de pixels brancos.

A segmentação realizada por meio do contorno ativo apresentou distorções em algumas imagens, em relação ao padrão-ouro estabelecido pelo ground-truth, manifestadas como a sub ou supersegmentação de lesões presentes nas ROIs contendo os nódulos mamários. Apesar disso, a segmentação por contorno ativo se demonstrou eficaz na detecção dos nódulos mamários em imagens mamográficas de todos os tipos de densidades mamárias, sendo validada por meio das análises qualitativa e quantitativa.

Logo, é fundamental aprimorar os parâmetros de segmentação (principalmente a máscara de segmentação) ou as técnicas de pré-processamento, visando eliminar as regiões irrelevantes e promover uma melhor segmentação dos nódulos presentes em imagens mamográficas.

5 CONCLUSÕES

O câncer de mama é a neoplasia mais diagnosticada do mundo. A detecção precoce do câncer aliada ao rastreamento mamográfico de rotina contribuem para uma melhoria no prognóstico e na qualidade de vida das pacientes afetadas. Entretanto, as imagens mamográficas apresentam características que dificultam a identificação precisa de nódulos pelos radiologistas. As técnicas de segmentação e pré-processamento têm como

objetivo aprimorar a interpretação das imagens mamográficas, visando promover uma detecção mais assertiva dos nódulos mamários.

A partir deste trabalho, é possível verificar a influência do pré-processamento nos resultados qualitativos e quantitativos das imagens. A suavização de ruído pelo filtro de Wiener, aplicada nas técnicas 2 e 4, resultou em valores mais distantes para as métricas de excentricidade e distância de Hausdorff. No entanto, apresentou os melhores resultados para a quantidade de pixels brancos. Já a técnica 3, que realiza um realce de contraste aplicando-se CLAHE somente nos coeficientes de aproximação da transformada *wavelet*, obteve os melhores resultados para a excentricidade calculada, indicando que foi a técnica que mais preservou o formato real do nódulo.

Além disso, a técnica 3 se destacou pela sua eficiência na detecção de lesões em mamas mais densas, pertencentes aos padrões de densidades mamárias c e d. Enquanto isso, a técnica 1 demonstrou maior eficácia na segmentação de nódulos de mamas correspondentes aos padrões a e b. Assim, conclui-se que a densidade mamária exerce uma influência determinante na efetividade das técnicas empregadas para a detecção e segmentação de nódulos mamários. Somado a isso, os resultados obtidos para a técnica 1, que consiste na aplicação do contorno ativo nas imagens sem pré-processamento, ressaltam a qualidade e eficácia do contorno ativo na segmentação de nódulos.

A excentricidade, a distância de Hausdorff e a contagem de pixels brancos serviram como indicadores para compreender o impacto das distintas técnicas de pré-processamento utilizadas antes da aplicação do contorno ativo. Essas métricas forneceram uma análise sobre o formato, precisão e extensão da área do nódulo segmentado, possibilitando uma avaliação mais detalhada do desempenho das técnicas utilizadas e a validação da eficácia na segmentação.

É relevante destacar que os métodos de processamento empregados nesta pesquisa, embora capazes de identificar as áreas com lesões, frequentemente se deparam com desafios de supersegmentação ou subsegmentação. No entanto, em linhas gerais, o contorno ativo demonstrou ser uma técnica muito boa na segmentação dos nódulos, apresentando eficácia na maioria das imagens segmentadas e constituindo uma técnica relativamente simples de implementação para imagens mamográficas abrangendo os quatro tipos de densidades mamárias existentes.

Portanto, por meio da realização deste trabalho, foi possível efetuar, com qualidade, a segmentação por contorno ativo de nódulos em imagens mamográficas com pré-processamentos distintos e avaliar a eficácia dessa segmentação por meio da análise visual e do cálculo das métricas: excentricidade, distância de Hausdorff e quantidade de pixels brancos na imagem. Os resultados encontrados permitiram, ainda, avaliar a influência dos diferentes pré-processamentos e densidades mamárias nos resultados de segmentação. Dessa forma, valida-se também a utilização das métricas calculadas neste trabalho.

Para trabalhos futuros, as análises podem ser expandidas com o cálculo de outras métricas, além da excentricidade, distância de Hausdorff e quantidade de pixels brancos. Além disso, outros tipos de pré-processamentos podem ser avaliados, bem como outros parâmetros de segmentação, como a máscara de segmentação aplicada no contorno ativo. Ainda, podem ser realizados testes com uma maior quantidade de imagens e ROIs. Dessa forma, espera-se aumentar ainda mais a efetividade da segmentação por contorno ativo na detecção de nódulos em imagens mamárias e reduzir distorções ocasionais.

REFERÊNCIAS

(Alberto, 2022)

ALBERTO, L. A. **Estudo de técnicas de segmentação de imagens baseadas em contorno ativo aplicadas em tomografia computadorizada de pulmão.** 2022.

(AMERICAN CANCER SOCIETY, 2022)

American Cancer Society. **Breast Cancer Early Detection and Diagnosis.** 2022. Disponível em: <https://www.cancer.org/content/dam/CRC/PDF/Public/8579.00.pdf>. Acesso em: 24 set 2023.

(Athanasίου; Fotiadis; Michalis, 2017)

ATHANASIOU, L. S.; FOTIADIS, D. I.; MICHALIS, L. K. **Atherosclerotic plaque characterization methods based on coronary imaging.** Academic Press. 2017.

(Bick, 2010)

BICK, U. **Digital mammography.** Heidelberg, Germany: Springer. 2010.

(Bushberg; Boone, 2011)

BUSHBERG, J. T.; BOONE, J. M. **The essential physics of medical imaging.** Lippincott Williams & Wilkins, 2011.

(Carneiro et al., 2019)

CARNEIRO, P. C. *et al.* **CLAHE Parameters Effects on the Quantitative and Visual Assessment of Dense Breast Mammograms.** IEEE Latin America Transactions, v. 17, n.5, p. 851-857. 2019. Disponível em: <https://doi.org/10.1109/TLA.2019.8891954>

(Carneiro, 2019)

CARNEIRO, P. C. **Proposta de metodologia para realce de contraste em imagens de mamas densas utilizando decomposição multiescala com transformada discreta wavelet.** 210 f. Tese (Doutorado em Engenharia Elétrica) - Universidade Federal de Uberlândia, Uberlândia. 2019. Disponível em: <https://doi.org/10.14393/ufu.te.2019.2593>.

(Chui, 2016)

CHUI, C. K. **An introduction to wavelets.** Elsevier, 2016.

(Ciecholewski, 2017)

CIECHOLEWSKI, M. **Malignant and benign mass segmentation in mammograms using active contour methods.** *Symmetry*, v. 9, n. 11, p. 277, 2017. Disponível em: <https://doi.org/10.3390/sym9110277>

(Civcik *et al.*, 2015)

CIVCIK, L. *et al.* **Detection of microcalcification in digitized mammograms with multistable cellular neural networks using a new image enhancement method: automated lesion intensity enhancer (ALIE)**. Turkish Journal of Electrical Engineering & Computer Sciences, v. 23, n. 3, p. 853-872, 2015. Disponível em: <https://doi.org/10.3906/elk-1303-139>

(Costa Junior, 2019)

COSTA JUNIOR, Carlos Alberto. **Proposta de uma metodologia para suavização de ruído em imagens mamográficas de mamas densas**. 76p. Dissertação (Mestrado em Engenharia Biomédica) – Faculdade de Engenharia Elétrica, Universidade Federal de Uberlândia, Uberlândia, 2019. Disponível em: <https://repositorio.ufu.br/handle/123456789/26605>

(Danziger, 2023)

DANZIGER, Z. **Hausdorff Distance**. MATLAB Central File Exchange. Retrieved November 12, 2023. Disponível em: <https://www.mathworks.com/matlabcentral/fileexchange/26738-hausdorff-distance>

(Daubechies, 1992)

DAUBECHIES, I. **Ten lectures on wavelets**. Siam. 1992.

(De Alexandria *et al.*, 2011)

DE ALEXANDRIA, A. R. *et al.* **Método de contornos ativos psnakes aplicado em imagens de ecocardiograma de eixo curto para cálculo de fração de ejeção**. Revista Brasileira de Engenharia Biomedica, [s. l.], v. 27, n. 3, p. 147–162, 2011. Disponível em: <https://doi.org/10.4322/rbeb.2011.012>

(Donoho; Johnstone, 1995)

DONOHO, D. L.; JOHNSTONE, I. M. **Adapting to unknown smoothness via wavelet shrinkage**. Journal of the american statistical association, v. 90, n. 432, p. 1200-1224, 1995. Disponível em: <https://doi.org/10.1080/01621459.1995.10476626>

(Dougherty, 2009)

DOUGHERTY, G. **Digital image processing for medical applications**. Cambridge University Press, 2009.

(Gonzalez; Woods, 2010)

GONZALEZ, R. C.; WOODS, R. E. **Processamento Digital de Imagens**. 3ª ed. São Paulo: Pearson Prentice Hall. 2010.

(INCA, 2007)

Instituto Nacional de Câncer. **Mamografia: da prática ao controle**. Ministério da Saúde. Instituto Nacional de Câncer. – Rio de Janeiro: INCA, 2007.

(INCA, 2022)

Instituto Nacional De Câncer José Alencar Gomes Da Silva. **Estimativa 2023: incidência do Câncer no Brasil**. 2022. Disponível em: <https://www.inca.gov.br/publicacoes/livros/estimativa-2023-incidencia-de-cancer-no-brasil>. Acesso em: 24 set 2023.

(Jackson *et al.*, 1993)

JACKSON, V. P. *et al.* **Imaging of the radiographically dense breast**. *Radiology*, v. 188, n. 2, p. 297-301, 1993. Disponível em: <https://doi.org/10.1148/radiology.188.2.8327668>

(Kannan *et al.*, 2016)

KANNAN, S. *et al.* **Performance comparison of noise reduction in mammogram images**. *Image*, v. 1, n. 3, 2016.

(Kass; Witkin; Terzopoulos, 1987)

KASS, M; WITKIN, A; TERZOPOULOS, D. **Sankes: Active contour models**. *International Journal of Computer Vision*, [s. l.], v. 1, n. 4, p. 321–331, 1987.

(Liu *et al.*, 2006)

LIU, W. *et al.* **Segmentation of elastographic images using a coarse-to-fine active contour model**. *Ultrasound in medicine & biology*, v. 32, n. 3, p. 397-408, 2006.

(Liu *et al.*, 2021)

LIU, K. *et al.* **Weakly-supervised high-resolution segmentation of mammography images for breast cancer diagnosis**. *Proceedings of machine learning research*, v. 143, p. 268, 2021.

(Logan; Kennedy; Catchpoole, 2023)

LOGAN, J.; KENNEDY, P. J.; CATCHPOOLE, D.. **A review of the machine learning datasets in mammography, their adherence to the FAIR principles and the outlook for the future**. *Scientific Data*, v. 10, n. 1, p. 595, 2023.

(Lu *et al.*, 2010)

LU, L. *et al.* **Comparative study of histogram equalization algorithms for image enhancement**. In: SPIE Defense, Security, and SENing. *International Society for Optics and Photonics*, 2010. p. 770811-770811-11. Disponível em: <https://doi.org/10.1117/12.853502>

(Luiz; Souza, 2014)

LUIZ, B. S.; SOUZA, M. F. A. **Utilização de Contorno Ativo para Segmentação de Nódulos em imagens de Mamografia**. 2014.

(Mahesh, 2004)

MAHESH, M. **AAPM/RSNA physics tutorial for residents: digital mammography: an overview**. *Radiographics*, v. 24, n. 6, p. 1747-1760, 2004. Disponível em: <https://doi.org/10.1148/rg.246045102>

(Mallat, 1989)

MALLAT, S. G. **A theory for multiresolution signal decomposition: the wavelet representation**. IEEE Transactions on Pattern Analysis & Machine Intelligence, n. 7, p. 674- 693, 1989.

(Mallat, 1999)

MALLAT, S. **A wavelet tour of signal processing**. Elsevier, 1999.

(Maqsood; DAMAŠEVIČIUS; MASKELIŪNAS, 2022)

MAQSOOD, S.; DAMAŠEVIČIUS, R.; MASKELIŪNAS, R. **TTCNN: A breast cancer detection and classification towards computer-aided diagnosis using digital mammography in early stages**. Applied Sciences, v. 12, n. 7, p. 3273, 2022.

(Marcomini; Schiabel; Verçosa, 2012)

MARCOMINI, K. D.; SCHIABEL, H.; VERÇOSA, L. B. **Aplicação de contornos ativos para a segmentação de nódulos em imagens de ultrassonografia da mama**. Revista Brasileira de Física Médica, v. 6, n. 2, p. 103-107, 2012. Disponível em: <https://doi.org/10.29384/rbfm.2012.v6.n2.p103-107>

(Mitchell; Basset, 1988)

MITCHELL JR, G. W.; BASSETT, L. W. **Mastologia prática**. Mastologia prática, 1988.

(Moreira *et al.*, 2012)

MOREIRA, I. C. *et al.* **Inbreast: toward a full-field digital mammographic database**. Academic radiology, v. 19, n. 2, p. 236-248, 2012.

(Nixon; Aguado, 2019)

NIXON, M.; AGUADO, A. **Feature extraction and image processing for computer vision**. Academic press, 2019.

(Persechino; De Albuquerque, 2015)

PERSECHINO, A.; DE ALBUQUERQUE, M. P. **Digital image processing: fundamental concepts**. MONOGRAFIAS-CBPF, v. 1, n. 4, 2015.

(Pedrini; Schwartz, 2008)

PEDRINI, H.; SCHWARTZ, W. R. **Análise de imagens digitais: princípios, algoritmos e aplicações**. Thomson, 2008.

(PIZER *et al.*, 1987)

PIZER, S. M. *et al.* **Adaptive histogram equalization and its variations**. **Computer vision, graphics, and image processing**, v. 39, n. 3, p. 355-368, 1987. Disponível em: [https://doi.org/10.1016/S0734-189X\(87\)80186-X](https://doi.org/10.1016/S0734-189X(87)80186-X)

(Poulos *et al.*, 2003)

POULOS, A. *et al.* **Breast compression in mammography: how much is enough?**. **Australasian radiology**, v. 47, n. 2, p. 121-126, 2003. Disponível em: <https://doi.org/10.1046/j.0004-8461.2003.01139.x>

(Radhi; Kamil, 2021)

RADHI, E. A.; KAMIL, M. Y. **Breast Tumor Detection Via Active Contour Technique**. International Journal of Intelligent Engineering & Systems, v. 14, n. 4, 2021.

(Rahmati; Adler; Hamarneh, 2012)

RAHMATI, P.; ADLER, A.; HAMARNEH, G. **Mammography segmentation with maximum likelihood active contours**. Medical image analysis, v. 16, n. 6, p. 1167-1186, 2012. Disponível em: <https://doi.org/10.1016/j.media.2012.05.005>

(Rezaee; Ahmadi; Anari, 2022)

REZAEI, K.; AHMADI, M. K. N.; ANARI, M. S. **Interactive Medical Image Segmentation using Active Contour with Improved F Energy in Level-Set Tuning**. Majlesi Journal of Electrical Engineering, v. 16, n. 2, p. 21-30, 2022.

(Rezende Junior; Carneiro; Patrocínio, 2018)

REZENDE JUNIOR, C. E. G.; CARNEIRO, P. C.; PATROCÍNIO, A.C. **Estudo do algoritmo CLAHE em mamas densas**. In: Anais do XI Simpósio de Engenharia Biomédica, Uberlândia, Minas Gerais, 2018. Disponível em: <https://doi.org/10.29327/xiseb.128309>

(Rodrigues, 2004)

RODRIGUES, S. C. M. **Organização automática de bancos de mamografias no padrão de densidade BI-RADS**. Tese de Doutorado. Universidade de São Paulo. 2004.

(Romualdo; Vieira; Schiabel, 2009)

ROMUALDO, L. C.; VIEIRA, M. A.; SCHIABEL, H. **Mammography images restoration by quantum noise reduction and inverse MTF filtering**. In: Computer Graphics and Image Processing (SIBGRAPI), XXII Brazilian Symposium on. IEEE, 2009. p. 180-185. 2009.

(Rowlands, 2002)

ROWLANDS, J. A. **The physics of computed radiography**. Physics in medicine and biology, v. 47, n. 23, p. R123, 2002.

(Sablón; Mendez, 2010)

SABLÓN, V. I. B.; MENDEZ, L. R.; IANO, Y. **A transformada wavelet no processamento e compressão de imagens**. Revista Ciência e Tecnologia, v. 6, n. 9, 2010.

(Saien; Moghddam; Fathian, 2018)

SAIEN, S.; MOGHADDAM, H. Ab.; FATHIAN, M. **A unified methodology based on sparse field level sets and boosting algorithms for false positives reduction in lung nodules detection**. International journal of computer assisted radiology and surgery, v. 13, p. 397-409, 2018.

(Sung *et al.*, 2021)

SUNG, H. *et al.* **Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries**. CA: a cancer journal for clinicians, v. 71, n. 3, p. 209-249, 2021.

(Singh *et al.*, 2021)

SINGH, S. *et al.* **Nature and biologically inspired image segmentation techniques**. Archives of Computational Methods in Engineering, p. 1-28, 2021. Disponível em: <https://doi.org/10.1007/s11831-021-09619-1>

(Soares, 2020)

SOARES, T. T. M. S. **Sistema para análise de imagens de imunohistoquímica para tecidos de carcinomas mamários utilizando técnicas de visão computacional e reconhecimento de padrões**. 2020.

(Souza; Angelo, 2014)

SOUZA, L. B. S.; ANGELO, M. F. **Utilização de contorno ativo para segmentação de nódulos em imagens de mamografia**, Universidade Estadual de Feira de Santana, Feira de Santana, Brasil, 2014.

(Syazwani Mohd Ghani; Jumaat; Mahmud, 2022)

SYAZWANI MOHD GHANI, N. A.; JUMAAT, A. K.; MAHMUD, R. **Boundary Extraction of Abnormality Region in Breast Mammography Image using Active Contours**. ESTEEM, v. 18, 2022.

(Ukwatta *et al.*, 2013)

UKWATTA, E. *et al.* **Three-dimensional segmentation of three-dimensional ultrasound carotid atherosclerosis using sparse field level sets**. Medical physics, v. 40, n. 5, p. 052903, 2013.

(Valarmathie; Sivakrithika; dinakaran, 2016)

VALARMATHIE, P.; SIVAKRITHIKA, V.; DINAKARAN, K. **Classification of mammogram masses using selected texture, shape and margin features with multilayer perceptron classifier**. Biomedical Research, Biomedical Research, 2016.

(Vaseghi, 2008)

VASEGHI, S. V. **Advanced digital signal processing and noise reduction**. John Wiley & Sons, 2008.

(Veltkamp; Hagerdoorn, 2001)

VELTKAMP, R. C.; HAGEDOORN, M. **State of the art in shape matching**. Principles of visual information retrieval, p. 87-119, 2001.

(Wolbarst, 1993)

WOLBARST, A. B. **Physics of radiology**. McGraw-Hill/Appleton & Lange, 1993.

(Whitaker, 1998)

WHITAKER, Ross T. **A Level-Set Approach to 3D Reconstruction from Range Data**. International Journal of Computer Vision, v. 29, n. 3, p. 203–231, 1998.

(Zuiderveld, 1994)

ZUIDERVELD, K. **Contrast limited adaptive histogram equalization**. In: Graphics gems IV. Academic Press Professional, Inc., 1994. p. 474-485. Disponível em: <https://doi.org/10.1016/b978-0-12-336156-1.50061-6>

(Zhao; Georganas; Petriu, 2010)

ZHAO, Y.; GEORGANAS, N. D.; PETRIU, E. M. **Applying contrast-limited adaptive histogram equalization and integral projection for facial feature enhancement and detection**. In: Instrumentation and Measurement Technology Conference (I2MTC), 2010 IEEE. IEEE, 2010. p. 861-866. Disponível em: <https://doi.org/10.1109/IMTC.2010.5488048>