



Pós-Graduação em Ciência da Computação

**DESENVOLVIMENTO DE UM MECANISMO SEMI-  
SUPERVISIONADO PARA SEGMENTAÇÃO DE TUMORES  
EM IMAGENS DE MAMOGRAFIA DIGITAL**

Por  
Filipe Rolim Cordeiro

Tese de Doutorado



Universidade Federal de Pernambuco  
posgraduacao@cin.ufpe.br  
<[www.cin.ufpe.br/~posgraduacao](http://www.cin.ufpe.br/~posgraduacao)>

RECIFE

2016



Universidade Federal de Pernambuco  
Centro de Informática  
Pós-graduação em Ciência da Computação

Filipe Rolim Cordeiro

**DESENVOLVIMENTO DE UM MECANISMO SEMI-SUPERVISIONADO  
PARA SEGMENTAÇÃO DE TUMORES EM IMAGENS DE  
MAMOGRAFIA DIGITAL**

*Trabalho apresentado ao Programa de Pós-graduação em  
Ciência da Computação do Centro de Informática da  
Universidade Federal de Pernambuco como requisito par-  
cial para obtenção do grau de Doutor em Ciência da  
Computação.*

Orientador: Abel Guilhermino da Silva Filho  
Co-orientador: Wellington Pinheiro dos Santos

RECIFE  
2016

Catálogo na fonte  
Bibliotecária Monick Raquel Silvestre da S. Portes, CRB4-1217

C794d Cordeiro, Filipe Rolim  
Desenvolvimento de um mecanismo semi-supervisionado para segmentação de tumores em imagens de mamografia digital / Filipe Rolim Cordeiro. – Recife: O Autor, 2016.  
202 f.: il., fig., tab.

Orientador: Abel Guilhermino da Silva Filho.  
Tese (Doutorado) – Universidade Federal de Pernambuco.  
Cln, Ciência da Computação, 2015.  
Inclui referências e apêndices.

1. Engenharia da computação. 2. Reconhecimento de padrão.  
3. Processamento de imagem. I. Silva Filho, Abel Guilhermino (orientador). II. Título.

621.39

CDD (23. ed.)

UFPE- MEI 2016-015



SERVIÇO PÚBLICO FEDERAL  
UNIVERSIDADE FEDERAL DE PERNAMBUCO  
CENTRO DE INFORMÁTICA  
PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Ata de Defesa de Defesa de Doutorado do  
Centro de Informática da Universidade Federal  
de Pernambuco, 16 de dezembro de 2015.

Ao décimo sexto dia do mês de dezembro do ano de dois mil e quinze, às treze horas, no Centro de Informática da Universidade Federal de Pernambuco, teve início a **ducentésima octogésima quarta** defesa de tese do Doutorado em Ciência da Computação, intitulada "**Desenvolvimento de um Mecanismo Semi-Supervisionado para Segmentação de Tumores em Imagens de Mamografia Digital**", elaborada sob a orientação do **professor Abel Guilhermino da Silva Filho**, do candidato **Filipe Rolim Cordeiro**, o qual já havia preenchido anteriormente as demais condições exigidas para a obtenção do grau de doutor. A Banca Examinadora, composta pelos professores Ricardo Bastos Cavalcante Prudêncio, Adriano Lorena Inacio de Oliveira, Paulo Salgado Gomes de Mattos Neto, todos pertencentes ao Centro de Informática desta Universidade, Fernando José Ribeiro Sales, pertencente ao Departamento de Engenharia Biomédica desta Universidade e Francisco Marcos de Assis, pertencente ao Departamento de Engenharia Elétrica da Universidade Federal de Campina Grande decidiu: **Aprovar** o trabalho. E para constar lavrei a presente ata que vai por mim assinada e pela Banca Examinadora Recife, 16 de dezembro de 2015.

---

Maria Lília Pinheiro de Freitas  
(secretária)

---

Prof. Ricardo Bastos Cavalcante Prudêncio  
Centro de Informática / UFPE

---

Prof. Adriano Lorena Inacio de Oliveira  
Centro de Informática / UFPE

---

Prof. Paulo Salgado Gomes de Mattos Neto  
Centro de Informática / UFPE

---

Prof. Fernando José Ribeiro Sales  
Departamento de Engenharia Biomédica / UFPE

---

Prof. Francisco Marcos de Assis  
Departamento de Engenharia Elétrica / UFCG

*Dedico esta tese à minha família, amigos e professores, que sempre estiveram presentes e me apoiaram sempre que precisei.*

## **Agradecimentos**

Agradeço a Deus, por ter me ajudado nos momentos mais difíceis e ter me dado saúde e força para chegar até aqui. Obrigado por não ter me deixado desistir e estar comigo todos os dias.

À minha família, em especial aos meus pais, por toda criação e educação e apoio que me deram e continuam a dar ainda hoje. Obrigado aos meus primos, em especial à Lara, Tulio e Tiago, que sempre me alegraram e tornaram meus dias melhores.

Ao meu orientador professor Abel Guilhermino, por ter me orientado desde a Iniciação Científica e ter contribuído significativamente na minha formação acadêmica. Agradeço por todas as instruções, orientações e conselhos que me ajudaram a chegar até aqui, por todo o aprendizado e amizade ao longo de tantos anos. Em especial, agradeço à orientação de mestrado e doutorado, que me permitiu atingir os objetivos de forma tranquila e com qualidade.

Agradeço também ao meu co-orientador Wellington Pinheiro, por ter me salvado nos momentos mais difíceis da pesquisa, e por ter me dado apoio quando eu mais precisei. Obrigado por ter me orientado contribuído para a conclusão da tese, artigos publicados, pelos ensinamentos, pela paciência e amizade.

Agradeço a todos os meus amigos, pelo apoio e motivação, por terem me aguentado cinco anos falando só sobre o doutorado, e sem os quais não estaria aqui. Agradeço aos meus amigos professores e alunos da UFRPE, por terem me dado apoio para o desenvolvimento da tese e por me ajudar a suportar as dificuldades. Obrigado em especial aos amigos que me incentivaram nos momentos mais difíceis: Gabriele, Péricles, Valmir, André e Tássia.

Agradeço em especial ao meu amigo Sidney, por ter me acompanhado nessa jornada e por ter me ajudado nas simulações, artigos, códigos, e por todo o apoio oferecido. Obrigado pelos ensinamentos na área de mamografia digital e pelo companheirismo.

Agradeço ainda a todos que de forma direta ou indireta contribuíram para a conclusão deste trabalho.

*“Foi o tempo que dedicastes à tua rosa que a fez tão importante.  
(Antoine de Saint-Exupéry)*

## Resumo

De acordo com a Organização Mundial de Saúde, o câncer de mama é a forma mais comum de câncer entre as mulheres no mundo todo, sendo um dos tipos de câncer mais fatal. Estudos mostram que o diagnóstico precoce pode contribuir para a redução da taxa de mortalidade e aumentar as opções de tratamento. Apesar da existência de várias técnicas de obtenção de imagens no auxílio ao diagnóstico de câncer de mama, a mamografia digital é ainda a tecnologia mais eficaz e utilizada para esse fim. Consequentemente, a segmentação de imagens de mamografia é uma tarefa fundamental para auxiliar o diagnóstico, levando em consideração a forma da lesão mamária e suas bordas. No entanto, a segmentação de imagens de mamografia é uma tarefa complexa, uma vez que ela é muito dependente dos tipos de tecido mamário e da lesão. O algoritmo GrowCut é um método de segmentação de propósito geral baseado em autômatos celulares, capaz de realizar uma segmentação precisa através da seleção adequada de pontos internos e externos à região de interesse. Neste trabalho é apresentado um novo algoritmo semi-supervisionado baseado na modificação do algoritmo GrowCut para realizar segmentação de imagens de mamografia de forma semi-automática. No método proposto é utilizada uma função de pertinência *fuzzy* Gaussiana para modificar a regra de evolução do algoritmo GrowCut original, visando estimar as probabilidades de um *pixel* pertencer ao objeto ou fundo da imagem. Esse modelo permite uma maior flexibilidade na inicialização das sementes quando comparado à trabalhos no estado da arte, pois a marcação realizada pelo especialista é utilizada extraindo-se informação do conjunto de sementes, e não informações do posicionamento individual, como o presente no GrowCut clássico. Foi também desenvolvido uma etapa de geração automática de sementes, onde apenas pontos internos da região de interesse são selecionados, através do uso do método de otimização Evolução Diferencial. Além disso, foi desenvolvido um método de ajuste de parâmetros adaptativo, que a partir da extração de características da imagem ajusta os melhores parâmetros para o algoritmo. A abordagem desenvolvida é comparada qualitativamente e quantitativamente com técnicas de segmentação do estado da arte BEMD, BMCS, WAGA, Abordagem Topográfica e MCW, usando métricas relacionadas à forma das regiões segmentadas. As análises são avaliadas utilizando regiões de interesse da base IRMA, totalizando 1.165 mamogramas. Resultados mostram que o algoritmo proposto obteve melhores resultados, considerando similaridade com imagem ouro, para as métricas utilizadas. Para validar a proposta, foi construído um classificador de imagem usando o Perceptron Multicamadas clássico. Resultados mostraram que a técnica proposta obteve taxa de classificação de 94,77%, evidenciando a viabilidade do método proposto.

**Palavras-chave:** Câncer de mama. Segmentação semi-supervisionada. Algoritmo GrowCut. Segmentação Fuzzy. Mamografia digital.

## Abstract

According to the World Health Organization, breast cancer is the most common cancer in women worldwide, becoming one of the most fatal types of cancer. Several studies show that the early diagnosis technologies can contribute to reduce the mortality rates and improve treatment options. Despite the existence of several imaging techniques to aid at the diagnosis of breast cancer, digital mammography is still the most used and effective imaging technology. Consequently, mammographic image segmentation is a fundamental task to support image diagnosis, considering shape analysis of mammary lesions and their borders. However, mammogram image segmentation is a hard task, once it is highly dependent on the types of mammary tissues. The GrowCut algorithm is a general-purpose segmentation method based on cellular automata, able to perform accurate segmentation through the adequate selection of internal and external points of the region of interest. Herein this work we present a new semi-supervised segmentation algorithm based on the modification of the GrowCut algorithm to perform semi-automatic mammographic image segmentation. In our proposal, we used a fuzzy Gaussian membership function to modify the evolution rule of the original GrowCut algorithm, in order to estimate the probabilities of a pixel being object or background. This model allows flexibility in the seeds initialization when compared to state of the art techniques, because the annotation executed by the specialist is used through the extraction of information of set of seeds, in opposite to the individual seeds information present in classical GrowCut. An automatic seed generation step was developed, where only the seeds internal to the region of interest are selected, using the Differential Evolution algorithm. Furthermore, we developed an adaptive parameter tuning method, which from the image characteristics it finds the best parameters to the algorithm. The proposed approach was qualitatively and quantitatively compared with other state-of-the-art segmentation techniques BEMD, BMCS, WAGA, Topographic Approach and MCW, using metrics related to the shape of segmented regions. The analysis are evaluated using regions of interest from IRMA database, totaling 1.165 mammograms. Results show that the proposed algorithm achieved better results, considering similarity with ground truth, for the used metrics. In order to validate our proposal we built an image classifier using a classical Multilayer Perceptron. This analysis employed 1.165 mammograms from IRMA breast cancer database. Results show that the proposed technique could achieve a classification rate of 94.77%, evidencing the feasibility of our approach.

**Keywords:** Breast cancer. Semi-supervised segmentation. GrowCut algorithm. Fuzzy segmentation. Digital mammography.

## Lista de ilustrações

Figura 1 – Processo de metástase realizado por um tumor maligno. . . . .	32
Figura 2 – Obtenção da imagem de mamografia digital e análise do diâmetro máximo da lesão. . . . .	33
Figura 3 – Distorção de avaliação entre dois profissionais em um exame de mamografia digital. . . . .	34
Figura 4 – Projeções nas quais a lesão pode ser visto. . . . .	34
Figura 5 – Tipos de tecido segundo a classificação do BI-RADS. (a) Tipo I, (b) Tipo II, (c) Tipo III, (d) Tipo IV. . . . .	36
Figura 7 – Grau de malignidade da lesão quanto à forma. . . . .	36
Figura 8 – Ilustração da composição da imagem por <i>pixels</i> . . . . .	38
Figura 9 – Variação de intensidade em imagens de tons de cinza. . . . .	39
Figura 10 – Variação de intensidade em imagens de tons de cinza. . . . .	39
Figura 11 – Quatro tipos básicos de imagem: escura, clara, baixo contraste, alto contraste e seus respectivos histogramas. O eixo horizontal corresponde aos níveis de tom de cinza (variando de 0 a 255) e o eixo vertical corresponde à frequência de cada nível na imagem. . . . .	40
Figura 12 – Variação de resolução com mesmo tamanho de imagem. . . . .	41
Figura 13 – Variação de resolução com tamanhos de imagens diferentes. . . . .	41
Figura 14 – Vizinhanças do <i>pixel</i> : (a) vizinhança 4; (b) vizinhança 8. . . . .	42
Figura 15 – (a) Imagem Original. (b) Imagem Segmentada. (c) Contorno da imagem segmentada sobreposta na imagem original. . . . .	43
Figura 17 – Histograma de intensidade dividido por um limiar único. Eixo horizontal: níveis de tom de cinza. Eixo vertical: frequência. . . . .	44
Figura 18 – (a) Impressão digital ruidosa. (b) Histograma. (c) Segmentação resultante usando um limiar global. . . . .	45
Figura 19 – (a) Imagem Original. (b) Região de Interesse. . . . .	46
Figura 21 – Funcionamento da filtragem espacial utilizando uma máscara 3x3. . . . .	47
Figura 22 – (a) Imagem digital $N \times N$ e (b) imagem mapeada em um círculo unitário. . . . .	50
Figura 23 – Funções de pertinência do ponto de vista da (a) lógica convencional e (b) da lógica fuzzy. . . . .	53
Figura 24 – Relação de dominância entre soluções, em um problema de minimização. . . . .	56
Figura 25 – Categorização das técnicas de segmentação de imagens de mamografia. . . . .	60
Figura 26 – Fluxograma da Técnica Contornos Ativos. . . . .	68
Figura 27 – Fluxograma da técnica Crescimento de Região. . . . .	69
Figura 28 – Corte de grafo de custo mínimo da técnica Graph Cut. . . . .	70
Figura 29 – Fluxograma do algoritmo Random Walks. . . . .	71

Figura 30 – Segmentação de um pássaro, com rótulos de objeto e fundo, utilizando Random Walks. . . . .	72
Figura 31 – Algoritmo EMD. . . . .	73
Figura 32 – Decomposição BEMD de sinal 2D. . . . .	74
Figura 33 – Processo de segmentação de lesão em imagem de mamografia baseada em BEMD. . . . .	75
Figura 34 – Processo de segmentação de lesão em imagem de mamografia do algoritmo BMCS. . . . .	76
Figura 35 – Processo de segmentação de lesões em imagem de mamografia do algoritmo MCW. . . . .	77
Figura 36 – Ilustração do modelo topografico. (a) Modelo de superfície e níveis de cinza. (b) Isocontornos sobrepostos na imagem. . . . .	79
Figura 37 – Ilustração da sobreposição de isocontornos. (a)Exemplo de Lesão. (b) Isocontornos no local da lesão. . . . .	79
Figura 39 – Ilustração da árvore de inclusão. (a) Mapa de isocontornos contendo contorno de ramo e contorno de base. (b) Árvore de inclusão correspondente. . . . .	80
Figura 41 – Abordagens de segmentação utilizadas em imagens médicas. . . . .	81
Figura 42 – Ataque à uma célula defensora, em vermelho, por sua vizinhança, em cinza. A célula defensora assume o rótulo do vizinho mais forte. O processo é repetido por todas as células da matriz. . . . .	86
Figura 43 – Evolução das células no GrowCut . . . . .	87
Figura 44 – Comparação da qualidade de segmentação baseada no número de sementes, para a imagem mdb184. . . . .	90
Figura 45 – Análise da distância entre as sementes e as bordas da lesão, para a imagem mdb028. . . . .	92
Figura 46 – Comparação entre a segmentação da técnica GrowCut e a imagem ouro, para as imagens mdb202, mdb025, mdb012, mdb015 e mdb134. . . . .	93
Figura 47 – Aplicação do Limiar Multinível em um região de interesse . . . . .	96
Figura 48 – Fluxograma do GrowCut Estendido. . . . .	97
Figura 49 – Seleção automática de sementes internas e externas. . . . .	98
Figura 50 – <i>Boxplot</i> dos erros de segmentação de Contornos Ativos, Graph Cut, Grow Cut, Crescimento de Região (CR), Random Walks e TGC, para as métricas de Área, Fator de Forma, Perímetro, FeretX, FeretY e Solidez, para a base Mini-MIAS. . . . .	103
Figura 51 – <i>Boxplot</i> dos erros de segmentação de Contornos Ativos, Graph Cut, Grow Cut, Crescimento de Região (CR), Random Walks e TGC, para as métricas AOM, Sensibilidade, Especificidade e BAC. . . . .	104

Figura 52 – Conceito de propagação de rótulos utilizado no GrowCut, baseado em informação local do posicionamento das sementes: (a) Sementes iniciais fornecidas pelo usuário; (b) propagação de rótulo a partir das sementes informadas pelo usuário. . . . .	107
Figura 53 – Conceito de propagação de rótulos utilizado no algoritmo proposto, baseado em informação global da localização das sementes: (a) Sementes iniciais fornecidas pelo usuário; (b) estimativa de uma região de probabilidade de ocorrência de lesão; (c) propagação de rótulos a partir do centro da região estimada. . . . .	108
Figura 54 – Região Gaussiana encontrada a partir de um conjunto de exemplos aleatórios bidimensionais com distribuição normal. . . . .	109
Figura 55 – Tamanho, localização e inclinação da região Gaussiana baseada em informação de média e desvio padrão dos dados. . . . .	109
Figura 56 – (a) Distribuição normal de pontos; (b) Regiões de probabilidade de pertinência à região Gaussiana ; (c) Região Gaussiana em três dimensões.	110
Figura 58 – (a) Região Gaussiana em duas dimensões; (b) Níveis de intensidade de uma lesão, em duas dimensões; (c) Região Gaussiana em três dimensões; (d) Níveis de intensidade de uma lesão, em três dimensões; (e) Níveis de intensidade d em duas dimensões;(f) Níveis de intensidade em três dimensões. . . . .	112
Figura 60 – (a)Imagem original contendo lesão; (b) Sementes iniciais (c) Região <i>Fuzzy</i> -Gaussiana com maior grau de pertinência à classe de lesão. . . .	113
Figura 62 – Fluxograma do Algoritmo Proposto. . . . .	114
Figura 63 – Imagem de entrada para o exemplo do algoritmo <i>Fuzzy</i> GrowCut: (a) Representação de uma imagem contendo uma região de lesão, em tons de cinza;(b) Matriz de valores intensidade de pixels correspondente. . .	117
Figura 64 – Inicialização do algoritmo proposto: (a) seleção de sementes; (b) cálculo do centro de massa das sementes; (c) matriz contendo a força inicial de cada célula. . . . .	117
Figura 65 – (a) Valores de grau de pertinência Gaussiana; (b)valores iniciais das células depois de calcular o grau de pertinência; (c) rótulos iniciais após calcular o grau de pertinência <i>Fuzzy</i> Gaussiana. . . . .	118
Figura 66 – (a) célula sendo atacada pelos vizinhos mais próximos; (b) atualização de força baseado na força da célula atacante; (c) rótulo sendo atualizado baseado no rótulo da célula atacante; (d) rótulo atualizado. . . . .	118
Figura 67 – Final da primeira iteração: (a) Atualização de força no final da primeira iteração; (b) atualização de rótulos no final da primeira iteração; (c) segmentação final . . . . .	119
Figura 68 – Mapeamento do indivíduo no modelo de geração automática de sementes.	122

Figura 69 – Fluxograma da Definição do Modelo de Equação de Parâmetros Adaptativo. Esse processo foi realizado apenas um única vez para definir o modelo de equação. . . . .	124
Figura 70 – Ajuste automático dos parâmetros de segmentação. . . . .	125
Figura 71 – Fluxo da Metodologia Proposta aplicada à base Mini-MIAS . . . . .	126
Figura 72 – Etapas da metodologia aplicada a imagem mdb132, do Mini-MIAS. (a) Imagem Original; (b) Geração automática de sementes; (c) Região <i>Fuzzy</i> Gaussiana (d) segmentação final comparada com a imagem ouro.	126
Figura 74 – Fluxo da Metodologia Proposta aplicada à base IRMA. . . . .	127
Figura 75 – Fluxo de Desenvolvimento do Projeto . . . . .	129
Figura 76 – Quantidade de regiões de interesse por tipo de lesão usadas para a base de dados Mini-MIAS. . . . .	131
Figura 77 – Proporção entre imagens com lesões benignas e malignas utilizadas para a base de dados IRMA. . . . .	133
Figura 78 – Fluxo da Metodologia Proposta para análise da qualidade de segmentação dos métodos utilizados. . . . .	135
Figura 79 – Fluxo de Análise de classificação das imagens segmentadas aplicada à base IRMA. . . . .	135
Figura 80 – Sementes geradas em diferentes simulações. . . . .	143
Figura 82 – Análise de convergência do modelo de geração automática de sementes.	144
Figura 84 – Análise de tolerância à falhas do posicionamento das sementes iniciais no GrowCut clássico. (a) ROI original; (b) Sementes selecionadas corretamente; (c) Segmentação obtida com as sementes da coluna (b); (d) Sementes selecionadas com um posicionamento incorreto da semente interna; (e) Segmentação obtida com as sementes da coluna (d); (f) Sementes selecionadas com um posicionamento incorreta da semente externa; (g) Segmentação obtida com as sementes da coluna (d). . . . .	145
Figura 86 – Análise de tolerância à falhas da localização das sementes iniciais para o GrowCut Fuzzy. (a) ROI original; (b) Sementes geradas corretamente; (c) Segmentação obtida com as sementes da coluna (b); (d) Sementes geradas com uma semente posicionada incorretamente; (e) Segmentação obtida com as sementes da coluna (d). . . . .	146
Figura 88 – Imagens de cada etapa do processo de segmentação do método proposto, para a base Mini-MIAS, para as imagens mdb010, mdb021, mdb028, mdb132, mdb063 e mdb181. (a) Região de Interesse; (b) Sementes geradas aleatoriamente; (c) Região <i>Fuzzy</i> Gaussiana; (d) Contorno da segmentação final comparado com a imagem ouro. . . . .	148

Figura 90 – Comparação da segmentação das técnicas analisadas, para as imagens mdb010, mdb021, mdb028, mdb190, mdb132 e mdb312. (a) Região de Interesse; (b) <i>Fuzzy</i> GrowCut; (c) Topográfico; (d) WAGA; (e) BEMD; (f) BMCS; (G) MCW. . . . .	149
Figura 92 – Valores médios para as métricas AOM, Sensibilidade, Especificidade e BAC, comparando as técnicas propostas com o estado arte, para todos os tipos de lesão. . . . .	151
Figura 93 – Valores médios para as métricas de Área, FF, Perímetro, FeretX, FeretY e Solidez, comparando as técnicas propostas com o estado arte, para todos os tipos de lesão. . . . .	151
Figura 94 – Valores médios para as métricas AOM, Sensibilidade, Especificidade e BAC, comparando as técnicas propostas com o estado arte, para as lesões do tipo circunscrito. . . . .	153
Figura 95 – Valores médios para as métricas de Área, FF, Perímetro, FeretX, FeretY e Solidez, comparando as técnicas propostas com o estado arte, para as lesões do tipo circunscrito. . . . .	153
Figura 96 – Valores médios para as métricas AOM, Sensibilidade, Especificidade e BAC, comparando as técnicas propostas com o estado arte, para as lesões do tipo espiculado. . . . .	155
Figura 97 – Valores médios para as métricas de Área, FF, Perímetro, FeretX, FeretY e Solidez, comparando as técnicas propostas com o estado arte, para as lesões do tipo espiculado. . . . .	155
Figura 98 – Valores médios para as métricas AOM, Sensibilidade, Especificidade e BAC, comparando as técnicas propostas com o estado arte, para as lesões do tipo indefinido. . . . .	156
Figura 99 – Valores médios para as métricas de Área, FF, Perímetro, FeretX, FeretY e Solidez, comparando as técnicas propostas com o estado arte, para as lesões do tipo indefinido. . . . .	156
Figura 100 – Segmentação do método proposto para as imagens da base de dados IRMA. (a) e (d) Região de Interesse; (b) e (e) Sementes geradas automaticamente e região <i>fuzzy</i> Gaussiana; (c) e (f) Segmentação Final. . .	158
Figura 102 – Comparação da segmentação das técnicas analisadas. (a) Região de Interesse; (b) <i>Fuzzy</i> GrowCut; (c) Abordagem Topográfica; (d) WAGA; (e) BEMD; (f) BMCS; (g) MCW. . . . .	159
Figura 104 – Valores médios para as métricas AOM, Sensibilidade, Especificidade e BAC, comparando as técnicas propostas com o estado arte, para as lesões do tipo circunscrito e espiculado, para a base IRMA. . . . .	161

Figura 105–Valores médios para as métricas de Área, FF, Perímetro, FeretX, FeretY e Solidez, comparando as técnicas propostas com o estado arte, para as lesões do tipo circunscrito e espiculado, para a base IRMA. . . . .	161
Figura 106–Valores médios para as métricas AOM, Sensibilidade, Especificidade e BAC, comparando as técnicas propostas com o estado arte, para as lesões do tipo circunscrito, para a base IRMA. . . . .	163
Figura 107–Valores médios para as métricas de Área, FF, Perímetro, FeretX, FeretY e Solidez, comparando as técnicas propostas com o estado arte, para as lesões do tipo circunscrito, para a base IRMA. . . . .	163
Figura 108–Valores médios para as métricas AOM, Sensibilidade, Especificidade e BAC, comparando as técnicas propostas com o estado arte, para as lesões do tipo espiculado, para a base IRMA. . . . .	164
Figura 109–Valores médios para as métricas de Área, FF, Perímetro, FeretX, FeretY e Solidez, comparando as técnicas propostas com o estado arte, para as lesões do tipo espiculado, para a base IRMA. . . . .	164
Figura 110–Boxplot dos resultados de taxa de classificação para as técnicas analisadas.	167
Figura 111–Segmentação do algoritmo proposto, usando imagens sem lesão. (a) Região de Interesse; (b) Sementes geradas automaticamente; (c) Segmentação Final. . . . .	169
Figura 113–Número de imagens do tipo normal identificadas corretamente, para cada técnica analisada. . . . .	170
Figura 114–Etapa de Classificação da Imagem Segmentada. . . . .	170
Figura 115–Arquitetura de uma rede neural MLP com duas camadas escondidas. . . . .	201

## Lista de tabelas

Tabela 1 – Momentos de Zernike utilizados. . . . .	51
Tabela 2 – Descritores de Haralick usados para extração de características. . . . .	51
Tabela 3 – Resumo dos principais trabalhos relacionados na segmentação supervisionada de lesões na mama. . . . .	64
Tabela 4 – Resumo dos principais trabalhos relacionados na segmentação não supervisionada de lesões na mama. . . . .	66
Tabela 5 – Resumo das principais abordagens de segmentação na área médica. . . . .	82
Tabela 6 – Principais técnicas de segmentação supervisionadas utilizadas em imagens médicas. . . . .	82
Tabela 7 – Média de erro das métricas analisadas, quando usados 1, 3, 6 e 9 pontos. . . . .	91
Tabela 8 – Erros estimados para as métricas de Fator de Forma, Área, Perímetro, Distância de <i>Feret</i> e Solidez. . . . .	94
Tabela 9 – Resultados de erro médio, máximo, mínimo e desvio padrão para todas as imagens analisadas. . . . .	94
Tabela 10 – Resultados da média, valor máximo, mínimo e desvio padrão para as métricas AOM, sensibilidade, especificidade e BAC, para todas as imagens analisadas. . . . .	95
Tabela 11 – Comparação entre a segmentação do GrowCut Topográfico e a imagem ouro, para as imagens mdb202, mdb025, mdb012, mdb015 e mdb134. . . . .	99
Tabela 12 – Comparação do <i>Slope Spectrum Pattern</i> da imagem ouro e do GrowCut Topográfico. . . . .	100
Tabela 13 – Resultados do teste do sinal ranqueado de Wilcoxon aplicado ao GrowCut Topográfico. . . . .	101
Tabela 14 – Comparação da segmentação final entre Graph Cut, GrowCut, GrowCut Topográfico, Crescimento de Região, Contornos Ativos e Random Walks, para as imagens mdb202, mdb025, mdb012, mdb015 e mdb134. . . . .	102
Tabela 15 – Teste Ranqueado de Wilcoxon aplicado para imagens segmentadas e imagens ouro, comparado a distribuição da métrica <i>Slope Spectrum Pattern</i> , para todas as técnicas analisadas. . . . .	105
Tabela 16 – Comparação entre o GrowCut e o Modelo Proposto. . . . .	120
Tabela 17 – Parâmetros utilizados no algoritmo Evolução Diferencial para a geração automática de sementes. . . . .	123
Tabela 18 – Quantidade de imagens de cada tipo na base de dados Mini-MIAS. . . . .	131
Tabela 19 – Número de imagens usadas da base IRMA na separado por tipo de lesão e tecido. . . . .	132

Tabela 20 – Número de imagens com imagem ouro da base IRMA separado por tipo de lesão e tecido. . . . .	133
Tabela 21 – Análise de Variação de Parâmetros do Algoritmo <i>Fuzzy</i> GrowCut, usando Evolução Diferencial. . . . .	142
Tabela 22 – Melhores parâmetros para os algoritmos BEMD, MCW e Abordagem Topográfica. . . . .	147
Tabela 23 – Média de valores das métricas analisadas, para todos os tipos de lesão da base Mini-MIAS, para as técnicas implementadas. . . . .	150
Tabela 24 – Valor do P-value do teste de sinal ranqueado de Wilcoxon, quando comparado os resultados do método <i>Fuzzy</i> GrowCut proposto com as técnicas analisadas. . . . .	150
Tabela 25 – Teste Ranqueado de Wilcoxon aplicado para imagens segmentadas e imagens ouro, comparado a distribuição da métrica <i>Slope Spectrum Pattern</i> , para todas as técnicas FGC, Topográfico, WAGA, BEMD, BMCS e MCW. . . . .	152
Tabela 26 – Média de valores das métricas para as técnicas analisadas, para lesões do tipo circunscrito. . . . .	152
Tabela 27 – Média de valores das métricas para as técnicas analisadas, para lesões do tipo espiculado. . . . .	154
Tabela 28 – Valor médio das métricas para as técnicas analisadas, para lesões do tipo indefinido. . . . .	154
Tabela 29 – Melhores parâmetros para os algoritmos BEMD, MCW ,Abordagem Topográfica e <i>Fuzzy</i> GrowCut, para a base IRMA, utilizando as métricas relacionadas a forma da lesão. . . . .	157
Tabela 30 – Valor médio das métricas para as técnicas analisadas, para lesões do tipo circunscrito e espiculado, para a base IRMA. . . . .	160
Tabela 31 – Valor do P-value do teste de sinal ranqueado de Wilcoxon, quando comparado os resultados do método <i>Fuzzy</i> GrowCut proposto com as técnicas analisadas, para a base IRMA, considerando lesões do tipo circunscrito e espiculado. . . . .	160
Tabela 32 – Valor médio das métricas para as técnicas analisadas, para lesões do tipo circunscrito, para a base IRMA. . . . .	162
Tabela 33 – Valor do P-value do teste de sinal ranqueado de Wilcoxon, quando comparado os resultados do método <i>Fuzzy</i> GrowCut proposto com as técnicas analisadas, para a base IRMA, considerando lesões do tipo circunscrito. . . . .	162
Tabela 34 – Valor médio das métricas para as técnicas analisadas, para lesões do tipo espiculado, para a base IRMA. . . . .	163

Tabela 35 – Valor do P-value do teste de sinal ranqueado de Wilcoxon, quando comparado os resultados do método <i>Fuzzy</i> GrowCut proposto com as técnicas analisadas, para a base IRMA, considerando lesões do tipo espiculado. . . . .	165
Tabela 36 – Melhores parâmetros para os algoritmos BEMD, MCW ,Abordagem Topográfica e <i>Fuzzy</i> GrowCut, para a base IRMA, utilizando a métrica de precisão. . . . .	166
Tabela 37 – Taxa de Classificação usando imagens segmentadas das técnicas analisadas, para tecidos adiposo e fibroglandular. . . . .	166
Tabela 38 – P-value do teste ranqueado de Wilcoxon comparando o método propostos <i>Fuzzy</i> GrowCut com as outras técnicas analisadas. . . . .	167
Tabela 39 – Características adotadas para identificar uma imagem sem lesão, para cada uma das técnicas analisadas. . . . .	168
Tabela 40 – Taxa de Classificação usando imagens segmentadas das técnicas analisadas, para tecidos adiposo e fibroglandular, incluindo imagens sem lesão. . . . .	171
Tabela 41 – Tempo médio de simulação (em segundos) de cada técnica analisada. .	171
Tabela 42 – Análise dos Parâmetros da Técnica de Segmentação por Abordagem Topográfica, para a base Mini-MIAS. . . . .	190
Tabela 43 – Análise dos Parâmetros da Técnica de BEMD, para a base Mini-MIAS.	191
Tabela 44 – Análise dos Parâmetros da Técnica MCW, para a base Mini-MIAS. . .	191
Tabela 45 – Análise dos Parâmetros da Técnica de Segmentação por Abordagem Topográfica, para a base IRMA, utilizando métricas relacionadas à forma.	192
Tabela 46 – Análise dos Parâmetros da Técnica de BEMD, para a base IRMA, utilizando as métricas relacionadas à forma. . . . .	193
Tabela 47 – Análise dos Parâmetros da Técnica MCW, para a base IRMA, utilizando as métricas relacionadas à forma. . . . .	193
Tabela 48 – Análise dos Parâmetros para do algoritmo proposto, para a base IRMA, utilizando-se a métricas relacionadas à forma. . . . .	194
Tabela 49 – Análise dos Parâmetros da Técnica de Segmentação por Abordagem Topográfica, para a base IRMA, utilizando-se a métrica de precisão. . .	195
Tabela 50 – Análise dos Parâmetros da Técnica de Segmentação por BEMD, para a base IRMA, utilizando-se a métrica de precisão. . . . .	196
Tabela 51 – Análise dos Parâmetros da Técnica de Segmentação por MCW, para a base IRMA utilizando-se a métrica de precisão. . . . .	196
Tabela 52 – Análise dos Parâmetros para do algoritmo proposto, para tecido tipo 1 da base IRMA, utilizando-se a métrica de precisão. . . . .	197
Tabela 53 – Análise dos Parâmetros para do algoritmo proposto, para tecido tipo 2 da base IRMA, utilizando-se a métrica de precisão. . . . .	198

Tabela 54 – Lista de imagens de lesão to tipo circunscrito e espiculado descartadas na análise de segmentação da base IRMA . . . . .	199
Tabela 55 – Equações dos Descritores de Haralick. . . . .	200

## Lista de abreviaturas e siglas

AFGC	<i>Adaptive Fuzzy GrowCut</i>
AOM	<i>Area Overlap Measure</i>
BAC	<i>Balanced Accuracy</i>
BEMD	<i>Bidimensional Intrinsic Mode</i>
BI-RADS	<i>Breast Imaging Reporting and Data System</i>
BMCS	<i>Breast Mass Contour Segmentation</i>
DDSM	<i>Digital Database for Screening Mammography</i>
DE	Evolução Diferencial
FF	Fator de Forma
Mini-MIAS	<i>Mini-Mammographic Image Analysis Society</i>
FGC	<i>Fuzzy GrowCut</i>
GA	<i>Genetic Algorithm</i>
INCA	Instituto Nacional do Câncer
IRMA	<i>Image Retrieval in Medical Applications</i>
LLNL	<i>Lawrence Livermore National Laboratory</i>
MCW	<i>Marker-Controlled Watershed</i>
MLP	<i>Multilayer Perceptron</i>
OMS	Organização Mundial de Saúde
ROI	<i>Region of Interest</i>
RNA	Rede Neural Artificial
SA	<i>Simulated Annealing</i>
SSP	<i>Slope Spectrum Pattern</i>
TGC	<i>Topographic GrowCut</i>
WAGA	<i>Wavelet Analysis and Genetic Algorithm</i>

## Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>24</b>
<b>1.1</b>	<b>Contexto e Motivação</b>	<b>24</b>
<b>1.2</b>	<b>Hipóteses do trabalho</b>	<b>27</b>
<b>1.3</b>	<b>Objetivos</b>	<b>28</b>
1.3.1	Objetivo Geral	28
1.3.2	Objetivos Específicos	28
<b>1.4</b>	<b>Escopo do Trabalho</b>	<b>29</b>
<b>1.5</b>	<b>Estrutura do Documento</b>	<b>29</b>
<b>2</b>	<b>DETECÇÃO E MEDIÇÃO DE LESÕES EM IMAGENS MÉDICAS</b>	<b>31</b>
<b>2.1</b>	<b>Câncer de Mama</b>	<b>31</b>
<b>2.2</b>	<b>Métodos para a Detecção e Medição de Tumores de Mama</b>	<b>32</b>
2.2.1	Exame Clínico	32
2.2.2	Mamografia	32
2.2.3	Ultrassonografia e Mamografia Digital	33
<b>2.3</b>	<b>Tipos de Tecido</b>	<b>35</b>
<b>2.4</b>	<b>Classificação de Lesões quanto à Forma</b>	<b>36</b>
<b>2.5</b>	<b>Considerações do Capítulo</b>	<b>37</b>
<b>3</b>	<b>CONCEITOS BÁSICOS DE PROCESSAMENTO DIGITAL DE IMAGEM E INTELIGÊNCIA COMPUTACIONAL</b>	<b>38</b>
<b>3.1</b>	<b>Fundamentos de Imagem Digital</b>	<b>38</b>
3.1.1	Histograma	39
3.1.2	Resolução Espacial	41
3.1.3	Vizinhança de um Pixel	42
3.1.4	Medidas de Distância	42
3.1.5	Segmentação	43
3.1.6	Imagem Ouro	43
3.1.7	Limiarização	44
3.1.8	Segmentação Baseada em regiões	46
3.1.9	Região de Interesse	46
3.1.10	Filtros	46
3.1.10.1	Filtro de Média	48
3.1.10.2	Filtro de Mediana	48
3.1.10.3	Filtro Laplaciano	48
3.1.11	Descritores de Imagem	49

3.1.11.1	Momentos de Zernike . . . . .	49
3.1.11.2	Descritores de Haralick . . . . .	50
<b>3.2</b>	<b>Conceitos de Inteligência Computacional . . . . .</b>	<b>51</b>
3.2.1	Classificadores . . . . .	52
3.2.2	Tipos de Aprendizado . . . . .	52
3.2.3	Lógica Fuzzy . . . . .	53
3.2.4	Algoritmos de Otimização . . . . .	55
<b>3.3</b>	<b>Considerações do Capítulo . . . . .</b>	<b>57</b>
<b>4</b>	<b>TRABALHOS RELACIONADOS . . . . .</b>	<b>58</b>
<b>4.1</b>	<b>Estado da Arte . . . . .</b>	<b>58</b>
4.1.1	Pré-processamento . . . . .	58
4.1.2	Segmentação . . . . .	59
4.1.3	Classificação . . . . .	65
<b>4.2</b>	<b>Algoritmos Supervisionados de Segmentação de Lesões Utilizados no Estado da Arte . . . . .</b>	<b>65</b>
4.2.1	Contornos Ativos . . . . .	65
4.2.2	Crescimento de Região . . . . .	68
4.2.3	Graph Cut . . . . .	69
4.2.4	Random Walks . . . . .	70
<b>4.3</b>	<b>Algoritmos Não Supervisionados de Segmentação de Lesões Utili- zados no Estado da Arte . . . . .</b>	<b>72</b>
4.3.1	BEMD . . . . .	72
4.3.2	BMCS . . . . .	74
4.3.3	MCW . . . . .	75
4.3.4	WAGA . . . . .	77
4.3.5	Modelo Topográfico . . . . .	78
<b>4.4</b>	<b>Análise de Algoritmos de Segmentação de Imagens Médicas . . . . .</b>	<b>80</b>
<b>4.5</b>	<b>Considerações do Capítulo . . . . .</b>	<b>83</b>
<b>5</b>	<b>ALGORITMO PROPOSTO . . . . .</b>	<b>85</b>
<b>5.1</b>	<b>Introdução . . . . .</b>	<b>85</b>
<b>5.2</b>	<b>Estudo do Algoritmo GrowCut . . . . .</b>	<b>85</b>
5.2.1	Descrição do GrowCut . . . . .	85
5.2.2	Análise de Segmentação de Lesões utilizando o GrowCut Clássico . . . . .	89
5.2.3	Extensão Proposta do GrowCut . . . . .	95
5.2.4	Análise do GrowCut Topográfico . . . . .	98
5.2.5	Comparação do GrowCut com Técnicas Supervisionadas . . . . .	101
5.2.6	Considerações da Análise de Segmentação do GrowCut . . . . .	105
<b>5.3</b>	<b>Descrição do Algoritmo Proposto . . . . .</b>	<b>106</b>

5.3.1	Seleção Automática de Sementes . . . . .	121
5.3.2	Seleção Adaptativa de Parâmetros . . . . .	123
5.3.3	Fluxo de Simulação . . . . .	125
<b>5.4</b>	<b>Considerações do Capítulo . . . . .</b>	<b>126</b>
<b>6</b>	<b>MATERIAIS E MÉTODOS . . . . .</b>	<b>128</b>
<b>6.1</b>	<b>Fluxo de Desenvolvimento do Projeto . . . . .</b>	<b>128</b>
<b>6.2</b>	<b>Ambiente Experimental . . . . .</b>	<b>130</b>
6.2.1	Mini-MIAS . . . . .	130
6.2.2	IRMA . . . . .	132
<b>6.3</b>	<b>Fluxo de Simulação . . . . .</b>	<b>134</b>
6.3.1	Fluxo de Análise de Segmentação . . . . .	134
6.3.2	Fluxo de Análise de Classificação . . . . .	134
<b>6.4</b>	<b>Técnicas Comparadas . . . . .</b>	<b>135</b>
<b>6.5</b>	<b>Métricas de Análise . . . . .</b>	<b>136</b>
6.5.1	Classificador . . . . .	138
<b>6.6</b>	<b>Considerações do Capítulo . . . . .</b>	<b>139</b>
<b>7</b>	<b>RESULTADOS E DISCUSSÃO . . . . .</b>	<b>141</b>
<b>7.1</b>	<b>Introdução . . . . .</b>	<b>141</b>
<b>7.2</b>	<b>Análise de Parâmetros do Algoritmo Proposto . . . . .</b>	<b>141</b>
<b>7.3</b>	<b>Análise de Convergência . . . . .</b>	<b>142</b>
7.3.1	Análise de Tolerância a Falhas . . . . .	143
<b>7.4</b>	<b>Resultados para a Base de Dados Mini-MIAS . . . . .</b>	<b>147</b>
<b>7.5</b>	<b>Resultados para a Base da Dados IRMA . . . . .</b>	<b>155</b>
7.5.1	Análise de Segmentação . . . . .	156
7.5.2	Análise de Classificação . . . . .	165
7.5.3	Análise com Imagens sem Lesão . . . . .	168
<b>7.6</b>	<b>Análise do Tempo de Simulação . . . . .</b>	<b>171</b>
<b>7.7</b>	<b>Discussão . . . . .</b>	<b>172</b>
<b>8</b>	<b>CONCLUSÃO E TRABALHOS FUTUROS . . . . .</b>	<b>173</b>
<b>8.1</b>	<b>Considerações Finais . . . . .</b>	<b>173</b>
<b>8.2</b>	<b>Contribuições . . . . .</b>	<b>174</b>
<b>8.3</b>	<b>Publicações do Trabalho . . . . .</b>	<b>175</b>
<b>8.4</b>	<b>Publicações Relacionadas . . . . .</b>	<b>175</b>
<b>8.5</b>	<b>Trabalhos Futuros . . . . .</b>	<b>176</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>178</b>

	<b>APÊNDICES</b>	<b>188</b>
	<b>APÊNDICE A – ANÁLISE DE PARÂMETROS DOS ALGORIT- MOS IMPLEMENTADOS. . . . .</b>	<b>189</b>
	<b>APÊNDICE B – BASE DE DADOS . . . . .</b>	<b>199</b>
	<b>APÊNDICE C – FUNDAMENTOS COMPUTACIONAIS. . . . .</b>	<b>200</b>
<b>C.1</b>	<b>Descritores de Haralick . . . . .</b>	<b>200</b>
<b>C.2</b>	<b>Multilayer Perceptron . . . . .</b>	<b>200</b>

# 1 INTRODUÇÃO

Este capítulo relata as principais motivações para realização deste trabalho, contextualizando acerca do problema de um diagnóstico mais preciso na identificação do câncer de mama, destacando a importância também da análise quanto à forma da lesão. São também apresentados neste capítulo os objetivos gerais e específicos do trabalho, o escopo da tese e, por fim, é descrito como está estruturado o restante deste documento.

## 1.1 CONTEXTO E MOTIVAÇÃO

O câncer de mama tem sido um problema crescente para mulheres do mundo todo. De acordo com a Organização Mundial de Saúde (OMS), ele é o tipo de câncer mais comum entre mulheres, com mortalidade crescente, tanto em países subdesenvolvidos como desenvolvidos, se tornando um dos tipos mais fatais (ORGANIZATION et al., 2014). Aproximadamente 1,7 milhões de novos casos foram diagnosticados em 2012, o que representa cerca de 12% de todos os novos casos de câncer e 25% de todo tipo de tumor em mulheres, com 522.000 mortes (DESANTIS et al., 2014). No Brasil, ele é a principal causa de morte por câncer entre as mulheres, sendo estimado 57.120 casos novos de câncer em 2014, com uma incidência de cerca de 56,09 casos a cada 100 mil mulheres, segundo o (INCA, 2014). Entre 2008 e 2012 houve um crescimento de incidência de câncer de mama de 20%, enquanto a mortalidade teve 14% de aumento (WHO, 2013). Mais da metade das mortes ocorreram em regiões menos desenvolvidas, e estima-se que essas proporções irão aumentar até 2025 (WHO, 2013). A baixa sobrevivência em países menos desenvolvidos está relacionada à falta de programas de detecção precoce (HARFORD, 2011). Isto ocorre porque a detecção precoce tem um impacto importante no sucesso do tratamento do tumor, sendo o tratamento mais difícil em estágios avançados (AUTIER et al., 2011). Vários métodos de prevenção têm sido desenvolvidos mas um dos métodos mais eficazes para a detecção da lesão é a mamografia digital, conforme descrito por Tortora e Derrickson (2012). No entanto, a interpretação da mamografia pode ser uma tarefa difícil até mesmo para um especialista, uma vez que a análise é afetada por diversos fatores, tais como a qualidade da imagem, experiência do radiologista e tipo de lesão. É estimado que 12% a 30% dos casos de câncer de mama deixam de ser detectados devido à má interpretação mamográfica (EVANS; BIRDWELL; WOLFE, 2013).

Estima-se que o período entre o surgimento do tumor e seu crescimento até ele se tornar palpável, alcançando cerca de 1 cm de diâmetro, é de aproximadamente 8 anos, onde a partir daí ele duplica de tamanho a cada período de 3 a 4 meses, conforme descrito por Abreu e Koifman (2002). Se não for tratado, o tumor entra em metástase (focos de tumor em outros órgãos), mais comumente nos ossos, pulmões e fígado (MEDEIROS et al., 2014).

Após três ou quatro anos do descobrimento do tumor pela palpação, o não tratamento do câncer pode ocasionar o óbito do paciente (INCA, 2002). Durante esse período, o imageamento da mama é essencial para o acompanhamento do tumor. A avaliação correta do tamanho da lesão tem um papel importante no planejamento do tratamento do câncer de mama, evitando cirurgias mutilantes, tais como a mastectomia (BANDEIRA et al., 2011). Como fator prognóstico, o tamanho da lesão determinará a indicação da realização da biópsia (MATHENGE et al., 2014), onde pode-se realizar uma cirurgia baseada na observação de uma área específica da mama.

Os dispositivos de imagens comumente empregados para a detecção de lesões provêm diversas funcionalidades que auxiliam o acompanhamento e diagnóstico da doença. No entanto, equipamentos de imagem determinados pelo Ministério da Saúde para a detecção do câncer de mama são bastante ineficientes para a avaliação do tamanho do nódulo (FURQUIM, 2014). Esses métodos dependem substancialmente na experiência do profissional examinador. Além disso, o diagnóstico através de imagens é complexo, principalmente devido à variância de lesões. Por essas razões, diagnósticos de mamografia auxiliados por computador (*Mammography Computer-Aided Diagnosis*, MCAD) têm tido um papel importante para ajudar radiologistas a melhorar a precisão dos diagnósticos (FENTON et al., 2011).

O auxílio ao médico na elaboração do diagnóstico serve como apoio à decisão para dúvidas que o profissional possa ter. Qualquer tipo de detecção que auxilie o profissional, seja descartando casos para análise, no caso de falsos-positivos, ou identificando anomalias celulares não percebidas pelo profissional, no caso de falso-negativos, contribui significativamente para o processo de tratamento do câncer. Consequentemente, diversas técnicas tradicionais de processamento de imagem têm sido aplicadas no campo médico para tornar o diagnóstico menos suscetível a erros através da identificação precisa da anomalia anatômica (YASMIN; MOHSIN; SHARIF, 2014).

O tamanho da lesão segmentada é um fator determinante no diagnóstico de mamografia, estando relacionado à sua gravidade. No entanto, pode ser bem difícil detectar o contorno exato de uma lesão, devido a diversos fatores, tais como forma, densidade, tamanho, localização e qualidade da imagem. Trabalhos na área são bastante precisos em identificar a localização das lesões (LIU et al., 2011; MOHAMED; BEHIELS; DEWAELE, 2009). Porém, poucos trabalhos têm sido realizados para verificar a qualidade da segmentação (RAHMATI; ADLER; HAMARNEH, 2012; CORDEIRO; SANTOS; SILVA-FILHOA, 2013). Além disso, os resultados dos trabalhos do estado da arte diferem significativamente entre si, sendo muitas vezes baseados em uma opinião visual do especialista e com um embasamento quantitativo muito pequeno, conforme observado por Raman et al. (2011). A identificação do contorno exato da lesão é um dos aspectos mais importantes na identificação do tipo de severidade da lesão. No entanto, a maioria dos trabalhos do estado da

arte utilizam apenas a métrica de sobreposição de *pixels* (XU; LIU; SONG, 2011; SONG et al., 2013), a qual nem sempre reflete a qualidade da forma da região segmentada, pois não analisa a segmentação quanto a forma da região obtida. Para obter uma segmentação precisa, é necessário também encontrar um contorno final próximo ao limite real da massa da lesão.

Em geral, regiões de lesões não possuem um contorno bem definido (DHEEBA; SINGH; SELVI, 2014). Por isso, técnicas baseadas em sementes (CORDEIRO; SANTOS; SILVA-FILHOA, 2013; ZHENG; LIU; LIU, 2013; CIESIELSKI et al., 2013), em que o usuário rotula *pixels* iniciais, apresentam melhor qualidade na segmentação final, porém requerem maior conhecimento especialista. Técnicas não supervisionadas, tais como as baseadas em Contornos Ativos (RAHMATI; ADLER; HAMARNEH, 2012) e Limiar Multinível (CHAKRABORTY et al., 2012), apresentam boa segmentação para lesões com contorno bem definidos, porém demonstram dificuldades em definir contornos do tipo espiculado ou com borda não definida. Métodos de segmentação supervisionados, tais como os baseados em sementes, onde o usuário rotula regiões iniciais com e sem lesão, têm obtido boa qualidade de segmentação quanto à forma dos objetos (WONGTHANAVASU, 2011; SAIDIN et al., 2013).

O algoritmo GrowCut, proposto por Vezhnevets e Konouchine (2005), é um método interativo de segmentação supervisionada pelo qual o usuário pode obter uma segmentação precisa através da seleção de alguns pontos dentro e fora da região de interesse. Essa característica faz o GrowCut ser uma ferramenta interessante para segmentar objetos de interesse em imagens em geral porque não é necessário nenhum outro parâmetro além da seleção de pontos. O algoritmo GrowCut é um algoritmo de segmentação de propósito geral baseado na dinâmica de autômatos celulares, conforme descrito por Vezhnevets e Konouchine (2005). Esses autômatos celulares são associados à *pixels*, os quais são previamente rotulados no estágio da seleção de pontos internos e externos à região de interesse. A interação entre as células do autômato resultam em uma rotulação dinâmica da imagem. Essa interação é guiada por regras competitivas, as quais são descritas em detalhe no Capítulo 5, no qual diagramas e pseudo-código do GrowCut são apresentados. Conseqüentemente, a evolução do autômato celular depende da seleção de pontos internos e externos à região de interesse, tornando possível uma boa segmentação de objetos relativamente difíceis e com bordas complexas, em um processo cuja qualidade é altamente dependente da experiência do usuário, segundo Vezhnevets e Konouchine (2005). Quanto maior a qualidade da seleção de pontos, isto é, quanto maior o conhecimento especialista usuário no posicionamento das sementes, melhor a qualidade dos resultados de segmentação da imagem. O GrowCut tem sido aplicado com sucesso em outras áreas, incluindo segmentação de imagens médicas (YAMASAKI et al., 2012), mas não havia sido analisado ainda para segmentação de mamografia.

## 1.2 HIPÓTESES DO TRABALHO

Os métodos supervisionados de segmentação de lesão são mais precisos e confiáveis para detecção de lesões com bordas indefinidas e complexas, quando comparados a métodos não supervisionados, conforme observado por Zhao e Xie (2013). No entanto, os métodos supervisionados são dependentes da marcação inicial de rótulos na imagem, também chamados de sementes, o que torna o resultado dependente da experiência do especialista. Isso acontece porque os métodos baseados na interação com o usuário, em sua maioria, utilizam a indicação do especialista como fonte de informação confiável para guiar o algoritmo de segmentação. Porém a indicação do especialista é passível de erro humano e dependente da experiência do profissional, o que tornam os métodos baseados em semente pouco robusto quanto à inicialização. A partir dessa premissa, segue o seguinte questionamento: se adicionarmos um modelo de imprecisão em um método iterativo podemos reduzir o esforço e necessidade do posicionamento correto de sementes? Baseado nesse questionamento consideramos a seguinte hipótese para o trabalho:

**Hipótese 1** *A localização da região de lesão fornecida pelo radiologista em um modelo supervisionado é naturalmente imprecisa, pois varia de acordo com o conhecimento do especialista. Portanto, é possível flexibilizar o posicionamento inicial da região de lesão, em um método de segmentação supervisionado, adicionando um modelo fuzzy que atribua níveis de pertinência à marcação, reduzindo o esforço especialista.*

A Hipótese 1 considera que a imprecisão é natural à seleção de sementes. Isso acontece tanto com métodos interativos quanto automáticos. A inserção de incerteza reduz o conhecimento especialista pois torna o método mais tolerante ao posicionamento incorreto das sementes. Isso deverá acontecer porque nesse modelo a semente possuirá um nível de incerteza associado ao seu posicionamento, tornando a segmentação baseada no nível de incerteza e não mais considerando o posicionamento inicial como certo. No entanto, será que é possível obter uma segmentação próxima à desejada ao adicionar um modelo de imprecisão? Baseado nesse questionamento consideramos a seguinte hipótese:

**Hipótese 2** *A identificação aproximada de regiões de lesão em um modelo de segmentação supervisionado baseado em sementes é suficiente para gerar uma segmentação próxima à imagem ouro, de acordo com as métricas de avaliação do estado da arte.*

Consideramos a hipótese 2, indicando que é possível obter uma segmentação bem definida através da identificação aproximada das sementes. O trabalho utilizará métricas de segmentação para comparar com os resultados obtidos com o modelo de imprecisão com resultados do estado da arte. No entanto, para realizar a implementação do modelo de imprecisão, precisamos considerar a seguinte hipótese:

**Hipótese 3** *As sementes iniciais de um modelo supervisionado podem ser mapeadas por uma função de pertinência.*

As hipóteses descritas foram a base para a adaptação do método de segmentação supervisionado GrowCut, inserindo-se um modelo de pertinência *fuzzy* gaussiana. Uma vez que a etapa de seleção de sementes do modelo não é mais necessária ser feita de forma exata, é possível utilizar um modelo de geração de sementes de forma automática, mantendo-se a qualidade da segmentação. As hipóteses definidas no trabalho serviram como base para condução dos experimentos realizados.

### 1.3 OBJETIVOS

Baseado no problema apresentado e nas hipóteses descritas, este trabalho possui um objetivo geral pelo qual são direcionados todos os esforços, os quais são definidos por alguns objetivos específicos. As próximas subseções abordam cada um deles.

#### 1.3.1 Objetivo Geral

O trabalho proposto tem como objetivo principal o desenvolvimento de uma nova técnica de segmentação de lesões em imagens de mamografia digital, a fim de permitir um diagnóstico mais preciso das lesões encontrados, fornecendo uma ferramenta de suporte à decisão para o médico. Têm-se como objetivo desenvolver um novo método de segmentação semi-supervisionado, a partir da adição de um modelo de incerteza em um método supervisionado, não paramétrico, que seja robusto quanto ao posicionamento de sementes iniciais e competitivo com trabalhos do estado da arte.

#### 1.3.2 Objetivos Específicos

O objetivo geral desse trabalho pode ser decomposto nos seguintes objetivos específicos:

- Desenvolvimento de um algoritmo de segmentação semi-supervisionado baseado em sementes, que seja menos dependente do posicionamento correto das sementes iniciais do que as técnicas do estado da arte;
- Mapeamento da localização das sementes iniciais em um modelo de incerteza;
- Redução da quantidade de marcações iniciais necessárias do algoritmo de segmentação, a fim de reduzir o esforço especialista e diminuir o impacto do posicionamento das sementes;

- Desenvolvimento de um método semi-supervisionado de segmentação, que a partir da região de interesse inicial de uma imagem de mamografia realize a segmentação da lesão de forma automática;
- Análise e validação dos resultados obtidos de forma qualitativa e quantitativa, utilizando métricas inerentes à forma da lesão segmentada, comparando os resultados obtidos do método proposto com os resultados das técnicas implementadas do estado da arte.

#### 1.4 ESCOPO DO TRABALHO

Este trabalho restringe-se à segmentação de lesões do tipo benigno circunscrito, maligno espiculado e maligno indistinto, para os tipos de tecido adiposo e fibroglandular. Para tecidos do tipo denso e extremamente denso a mamografia digital perde a sensibilidade, sendo indicado a ultrassonografia complementar para o diagnóstico mais preciso. Desta forma, foram utilizadas apenas imagens de tecidos do tipo adiposo e fibroglandular. Além disso, não foram consideradas imagens contendo calcificações, pois envolvem outras abordagens de segmentação.

#### 1.5 ESTRUTURA DO DOCUMENTO

Este documento encontra-se estruturado da seguinte forma:

##### 1. **Capítulo 1: Introdução**

O primeiro capítulo contextualizou este trabalho através do relato das principais motivações envolvidas, listando os objetivos de pesquisa almejados e por fim, discriminando como está estruturado o restante do documento.

##### 2. **Capítulo 2: Detecção e Medição de Lesões em Imagens Médicas**

Esse capítulo fornece uma visão geral dos principais métodos de obtenção de imagem digital da mama e dificuldades de diagnósticos na área. É apresentado também a definição dos diferentes tipos de lesão e ressaltada a importância de uma boa segmentação para diferenciar cada tipo de lesão com maior precisão.

##### 3. **Capítulo 3: Conceitos Básicos de Processamento Digital de Imagem e Inteligência Computacional**

Esse capítulo fornece conceitos introdutórios sobre os fundamentos de imagem digital e técnicas de processamento de imagens. O capítulo também descreve conceitos de inteligência computacional. Espera-se que esse capítulo forneça os fundamentos necessários para o entendimento dos termos e técnicas utilizados ao longo do documento.

#### 4. **Capítulo 4: Trabalhos Relacionados**

Esse capítulo tem como objetivo apresentar as principais contribuições realizadas nos últimos anos no contexto de segmentação de lesões em imagens de mamografia digital. Além disso, são referenciados os principais trabalhos que serviram como base para o desenvolvimento do trabalho proposto.

#### 5. **Capítulo 5: Algoritmo Proposto**

Esse capítulo apresenta a descrição do algoritmo proposto, mostrando a estratégia utilizada e as equações envolvidas no algoritmo. Além disso, são apresentados os impactos da proposta na segmentação de lesões.

#### 6. **Capítulo 6: Materiais e Métodos**

O objetivo desse capítulo é apresentar a metodologia utilizada ao longo do trabalho. Nesse capítulo, é definido o ambiente experimental utilizado, assim como o método de simulação e métricas de análise dos resultados.

#### 7. **Capítulo 7: Resultados**

O objetivo desse capítulo é apresentar os resultados obtidos utilizando o método proposto e as técnicas do estado da arte. Esse capítulo mostra o resultado das métricas utilizadas, identificando a qualidade de segmentação de cada algoritmo.

#### 8. **Capítulo 8: Conclusão e Trabalhos Futuros**

Este capítulo tem como objetivo apresentar as considerações finais sobre os principais tópicos abordados neste trabalho, incluindo as contribuições alcançadas e indicações para trabalhos futuros.

Resultados adicionais do Capítulo 8 podem ser encontrados no Apêndice A.

## 2 DETECÇÃO E MEDIÇÃO DE LESÕES EM IMAGENS MÉDICAS

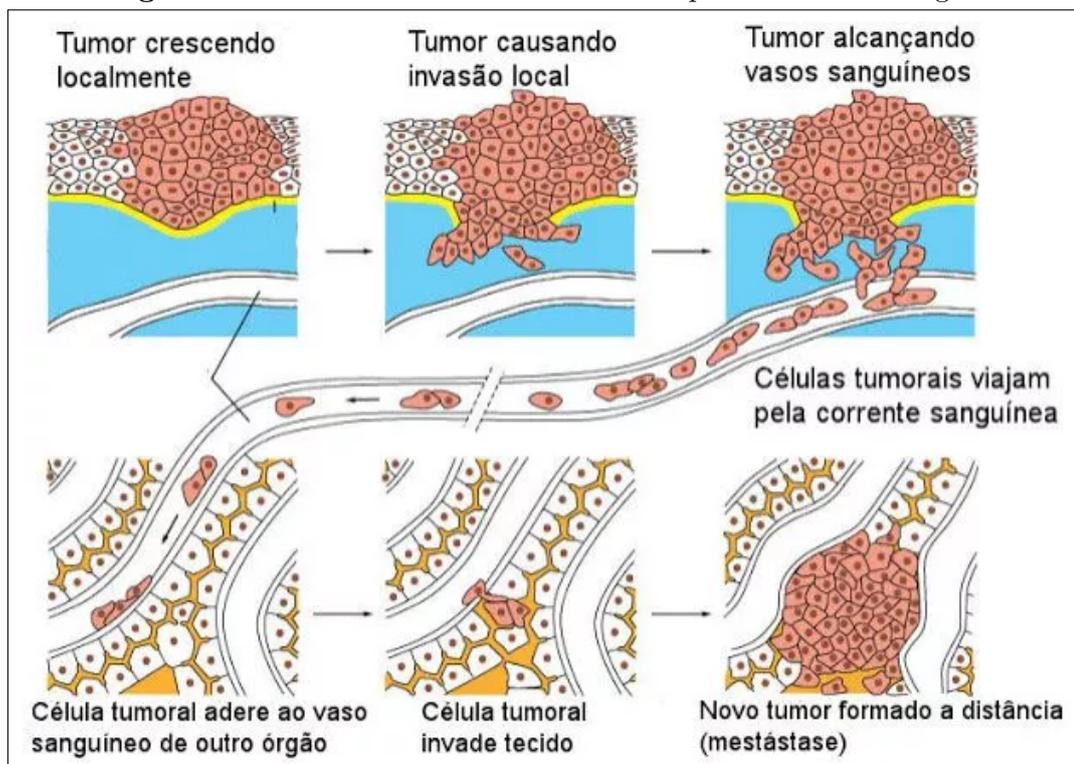
Este capítulo apresenta conceitos iniciais sobre a formação de tumores no tecido mamário, apresentando as características e tipos de lesões mais comuns. Também são apresentadas as técnicas de detecção e medição de lesões, mostrando a importância de um diagnóstico preciso e como a identificação do contorno da lesão por auxílio do computador pode melhorar a qualidade do diagnóstico médico.

### 2.1 CÂNCER DE MAMA

A melhor forma de combater câncer é através da detecção precoce do tumor (MINEO et al., 2013). Inicialmente é identificada a presença de lesão no tecido mamário, o qual posteriormente é confirmada a presença de tumor na região. Quanto mais cedo for identificada a lesão, mais fácil e eficiente será o tratamento da doença caso haja tumor. No entanto, identificar o tumor em estágios iniciais é ainda mais difícil e, por consequência, há uma maior dependência de equipamentos de obtenção de imagem e técnicas de segmentação mais eficientes, além de uma maior experiência do radiologista.

O câncer de mama é uma doença causada pela multiplicação anormal das células da mama, que cresce mais rápido do que os tecidos normais adjacentes, de modo descoordenado e persistente (BELTRÃO-BRAGA; TEIXEIRA; CHAMMAS, 2002). Esse crescimento anormal cria novas células que se agrupam e formam o tumor, que invade os tecidos vizinhos. Esse conjunto de células tem a capacidade de se desprender do tecido e migrar para outras partes do corpo, caracterizando as chamadas metástases. Esse processo é ilustrado na Figura 1, retirada do artigo de Pinheiro (2014). Essas células podem percorrer pela circulação ou pelo sistema linfático e alcançar outros órgãos, onde perdem sua função especializada e, à medida que substituem as células normais, comprometem a função do órgão afetado.

Os tumores são classificados em benignos e malignos. Entretanto, o termo *câncer* é utilizado apenas para tumores malignos. Os tumores benignos não possuem capacidade de realizar metástase e as células crescem lentamente e semelhante às do tecido normal. Na maioria dos casos pode ser totalmente removido por meio de cirurgia. No tumor maligno as células multiplicam-se rapidamente e possuem a capacidade de realizar metástase. A cura neste tipo de tumor tem melhor prognóstico dependendo se houve diagnóstico precoce e do tratamento adotado.

**Figura 1** – Processo de metástase realizado por um tumor maligno.

Fonte: (PINHEIRO, 2014)

## 2.2 MÉTODOS PARA A DETECÇÃO E MEDIÇÃO DE TUMORES DE MAMA

Entre os métodos de detecção e medição de tumores mais utilizados do Brasil, destacam-se três: exame clínico, ultrassonografia e mamografia (MARQUES; GUTIÉRREZ; FIGUEIREDO, 2015).

### 2.2.1 Exame Clínico

O exame clínico é um procedimento completamente manual. Neste método, o médico examina manualmente a mama da paciente, tentando encontrar sua localização. Segundo MONTEIRO e SIQUEIRA (2008) Quando uma lesão é encontrada, ela é fixado entre os dedos e mensurado através de uma régua milimetrada flexível. O exame clínico não deve ser a única forma de diagnóstico adotada, pois o tumor leva cerca de 8 anos para se tornar palpável, de acordo com Abreu e Koifman (2002). Desta forma, quando ele se torna palpável o mesmo pode se encontrar em um estágio desenvolvido.

### 2.2.2 Mamografia

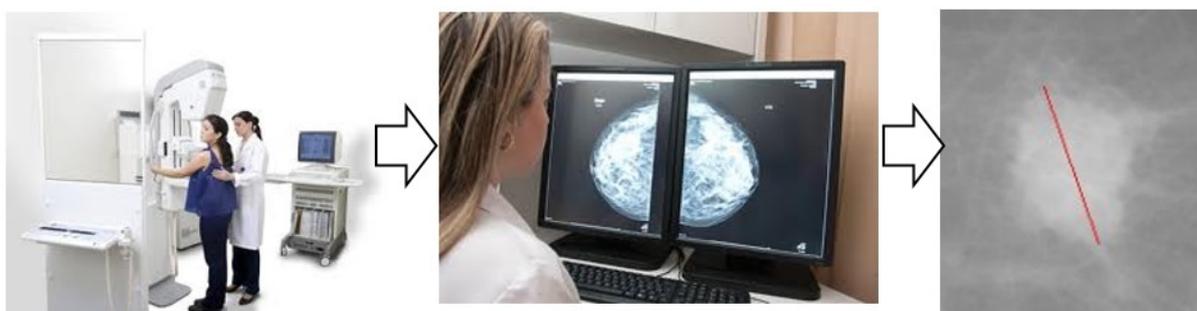
A mamografia é o exame de diagnóstico com a utilização dos Raios-X para estudos da mama. O exame de mamografia é realizado através de um aparelho chamado mamógrafo, no qual o paciente é posicionado e radiografado. A imagem da mama, chamada de mamograma,

é obtida pela compressão das mamas, utilizando-se placas planas. O tamanho da lesão é aferido na mamografia através de uma régua milimetrada aplicada ao filme (chapa) resultante do exame. Por ser um método manual há um esforço e custo de tempo associados, além de aumentar a possibilidade de erros de medição.

### 2.2.3 Ultrassonografia e Mamografia Digital

A ultrassonografia e a mamografia digital são métodos, determinados pelo Ministério da Saúde em que a lesão é mensurada com o suporte do computador. Segundo Tortora e Derrickson (2012), a técnica mais eficaz para detecção de lesões menores do que 1cm de diâmetro é a mamografia digital. A Figura 2 mostra o processo de obtenção e análise da imagem da lesão.

**Figura 2** – Obtenção da imagem de mamografia digital e análise do diâmetro máximo da lesão.

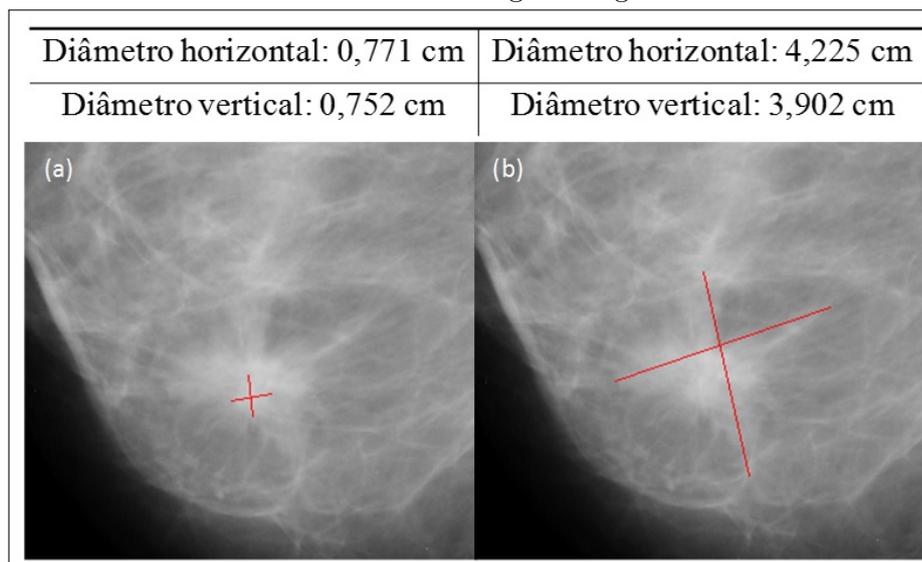


Fonte: (IMAX DIGITAL, 2012; BEROALDO JUREMA, 2015)

Inicialmente, é utilizado o mamógrafo para realizar o raio x da mama. Nele, a mama é comprimida, de forma a fornecer melhores imagens, gerando os mamogramas digitais. Uma vez obtida a imagem de mamografia digital, o radiologista faz uma análise a fim de detectar alguma região contendo lesão. Caso encontre uma lesão, o radiologista realiza a análise quanto à forma e ao seu diâmetro máximo para poder fornecer um diagnóstico apropriado. No entanto, essa análise ainda depende bastante da experiência do radiologista. Como exemplo, a imagem da Figura 3, analisada na dissertação de Lima (2011), mostra a diferença de análise de uma mesma imagem feita por dois radiologistas em Recife.

Pode-se observar na Figura 3 que há uma discrepância entre as marcações realizadas pelos especialistas. Nessas marcações, que são utilizadas na prática clínica local, o médico tenta identificar os diâmetros máximo horizontal e vertical. Caso o tamanho do diâmetro máximo da lesão ultrapasse 3cm, na maioria dos casos é indicado a realização de uma cirurgia de remoção de mama. Porém, há uma grande imprecisão nesse método, pois a lesão completa é representada através de apenas 4 pontos, dois no eixo vertical e dois horizontais no eixo horizontal, e todas as suas demais informações são desconsideradas. Outra imprecisão se dá pelo fato dos pontos formadores dos diâmetros serem inseridos

**Figura 3** – Distorção de avaliação entre dois profissionais em um exame de mamografia digital.

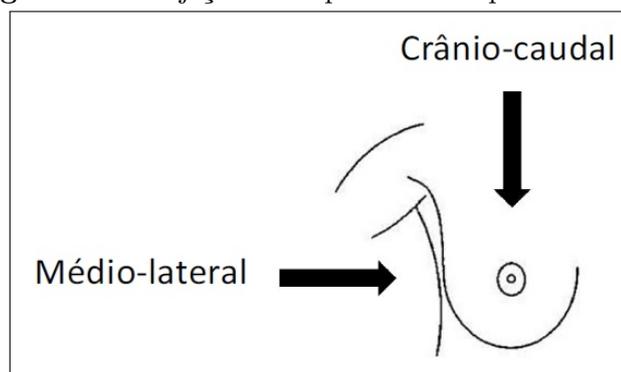


Fonte: (LIMA, 2011).

através do mouse. No caso da Figura 3 (a), por exemplo, um profissional identificou a região de lesão como sendo pequena, com diâmetro máximo menor que 1cm. Já no caso da Figura 3 (b), um outro profissional analisou a mesma imagem e indicou que o diâmetro máximo era maior que 3 cm. A diferença de diagnóstico, no entanto, interfere diretamente na qualidade de vida da paciente e tem grande impacto psicológico, onde o diagnóstico errado da lesão pode avaliar incorretamente um tumor em estágio avançado.

Apesar de haver vários estudos sobre qual dos métodos vistos é o melhor na investigação do tamanho da lesão na mama (SHAO et al., 2013; SICKLES; KUBIK-HUCH; MÜLLER-SCHIMPFLE, 2011), ambos são dependentes demasiadamente da experiência do profissional examinador. Logo, a mensuração do tumor, através desses exames, se torna bastante subjetiva e sujeita a diversas interpretações.

**Figura 4** – Projeções nas quais a lesão pode ser visto.



Fonte: (LIMA, 2011).

Uma lesão deve ser vista nas projeções crânio-caudal e médio-lateral, conforme mostrado na Figura 4. A lesão tem característica benigna quando seu eixo maior está paralelo à pele. Isso quer dizer que na projeção crânio-caudal o diâmetro máximo deve ter orientação horizontal, ou na projeção médio-lateral, o máximo diâmetro deve ter orientação vertical. A lesão tem característica maligna quando o diâmetro máximo está perpendicular à pele. Então, na projeção médio-lateral, o máximo diâmetro deve ter orientação horizontal.

Isso mostra como é importante a definição exata do contorno da lesão, obtendo seu diâmetro máximo, para identificar o diagnóstico correto.

### 2.3 TIPOS DE TECIDO

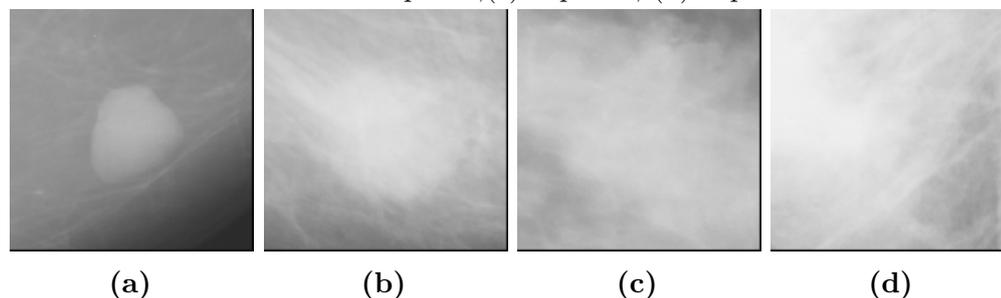
A classificação proposta pelo Colégio Americano de Radiologia, desenvolvida por Liberman e Menell (2002) junto ao Registro de Imagem da Mama e Sistema de Dados (*Breast Imaging Reporting and Data System*, BI-RADS), reconhecida pelo Colégio Brasileiro de Radiologia por Imagem (CBR), através da Comissão Nacional de Mamografia, é a que tem a maior aceitação por apresentar simplicidade, abrangência e fácil entendimento (TEIXEIRA, 2011). Essa classificação considera quatro padrões de densidade do tecido mamário:

- tipo I: mamas predominantemente adiposas (25% do componente fibroglandular);
- tipo II mamas parcialmente gordurosas (com densidades de tecido fibroglandular ocupando de 26% a 50% do volume da mama);
- tipo III: mamas com padrão denso e heterogêneo (51% a 75% de tecido fibroglandular, dificultando a visualização de nódulos);
- tipo IV: mamas muito densas, apresentando mais de 75% de tecido fibroglandular, diminuindo a sensibilidade da mamografia.

A Figura 5 mostra imagens de mamografia para cada tipo de tecido, segundo a classificação do BI-RADS. Geralmente as regiões mais claras da imagens representam regiões com lesão.

As imagens de mama predominantemente adiposas, representadas pela Figura 5(a) normalmente possuem maior contraste entre tecido mamário e região de lesão, tornando-se mais fáceis de serem diagnosticadas corretamente. Para mamas do tipo II, tipo III e tipo IV, o tecido mamário confunde-se com a região de lesão, na imagem de mamografia, tornando-se difícil a detecção da dimensão correta.

**Figura 5** – Tipos de tecido segundo a classificação do BI-RADS. (a) Tipo I, (b) Tipo II, (c) Tipo III, (d) Tipo IV.

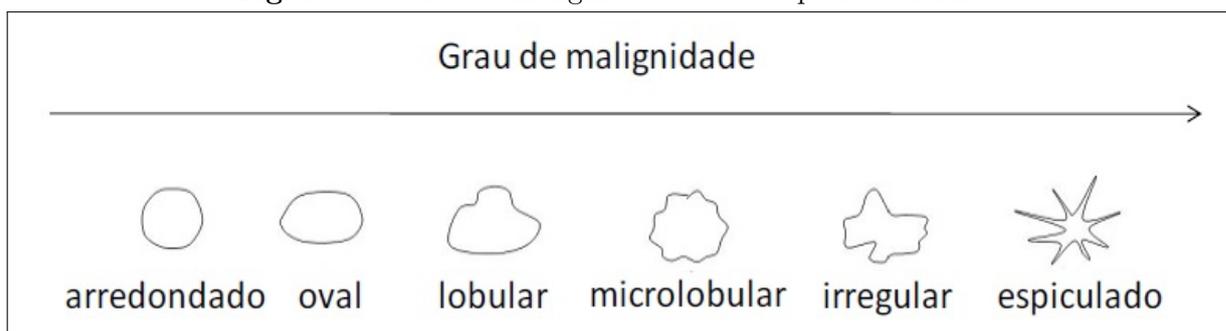


Fonte: (DESERNO et al., 2011).

## 2.4 CLASSIFICAÇÃO DE LESÕES QUANTO À FORMA

O BI-RADS determina a classificação dos lesões quanto à forma, conforme mostra a Figura 7.

**Figura 7** – Grau de malignidade da lesão quanto à forma.



Fonte: (LIMA, 2011).

As lesões de forma arredondada são aproximadamente circulares. Já os ovais descrevem uma elipse. Os lobulares possuem contornos ondulados, enquanto os microlobulados dizem respeito a uma lesão com mais do que três ondulações. Lesões irregulares são aqueles que não se encaixam em nenhuma dessas classificações. Já a lesão espiculada é quando a lesão possui linhas radiantes.

Uma determinação bem delimitada e precisa é essencial para ser realizada uma classificação correta quanto ao tipo de lesão. Apesar dos diferentes tipos de lesão determinados pelo BI-RADS, a maioria das bases de imagens de mamografia possuem apenas imagens com lesões do tipo arredondado, espiculado e irregular (SUCKLING et al., 1994; DESERNO et al., 2012).

## 2.5 CONSIDERAÇÕES DO CAPÍTULO

Neste capítulo foram apresentadas alguns dos principais métodos de detecção de lesão na mama. Foi possível observar como esse tipo de procedimento atualmente é bastante dependente da experiência do profissional e o quanto um diagnóstico errado pode impactar na vida de uma paciente. Além do mais, a identificação do contorno do lesão é de extrema importância para o diagnóstico correto, identificando o grau de malignidade para assim seguir com o tratamento mais adequado. Por fim, é perceptível como a aplicação de técnicas computacionais, através de ferramentas de auxílio ao diagnóstico, podem ajudar na prevenção do câncer e na diminuição do número de mortes causados pela doença.

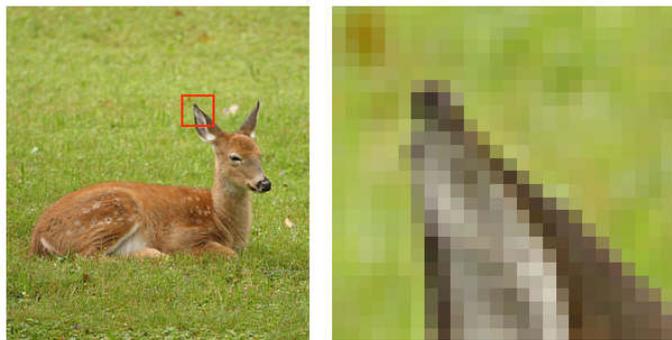
### 3 CONCEITOS BÁSICOS DE PROCESSAMENTO DIGITAL DE IMAGEM E INTELIGÊNCIA COMPUTACIONAL

Esse capítulo apresenta conceitos básicos sobre processamento digital de imagem e inteligência computacional, os quais serão necessários para o entendimento das técnicas e dos termos utilizados ao longo desse documento. Neste capítulo são apresentados os conceitos de fundamentos de imagem, histograma digital, histograma, medidas de distância, limiarização, segmentação e filtros. Também são descritos conceitos de inteligência computacional, tais como tipo de aprendizado, lógica *fuzzy*, otimizadores e classificadores.

#### 3.1 FUNDAMENTOS DE IMAGEM DIGITAL

Uma imagem pode ser definida como uma função bidimensional,  $f(x, y)$ , onde  $x$  e  $y$  são coordenadas espaciais, e o valor de  $f$  em qualquer par de coordenadas  $(x, y)$  é chamada de intensidade, ou nível de cinza em uma imagem monocromática, da imagem neste ponto. Quando  $x$ ,  $y$  e os valores de intensidade de  $f$  são finitos e possuem quantidades discretas, chama-se a imagem de imagem digital. Os elementos que compõem a imagem digital, cada um com localização e valor específico, são chamados de *pixels*. Desta forma, o *pixel* é o menor elemento que compõe uma imagem digital, e ele possui um valor de intensidade. Cada *pixel* possui uma cor, representado em um ponto da imagem. A Figura 8 mostra como uma imagem digital é composta por *pixels*.

**Figura 8** – Ilustração da composição da imagem por *pixels*.



Fonte: (ARAÚJO, 2015).

Uma imagem em tons de cinza é uma imagem composta por *pixels* que possuem um valor de intensidade correspondente ao nível de cinza em um ponto específico da imagem. Esses tons de cinza variam entre branco e preto em 256 níveis diferentes. A Figura 9 mostra as variações de tons de cinza em uma imagem 256 níveis de cinza.

A imagem em tom de cinza difere da imagem binária, que é aquela que apresenta apenas duas intensidades correspondentes ao preto e ao branco. A imagem em tons de

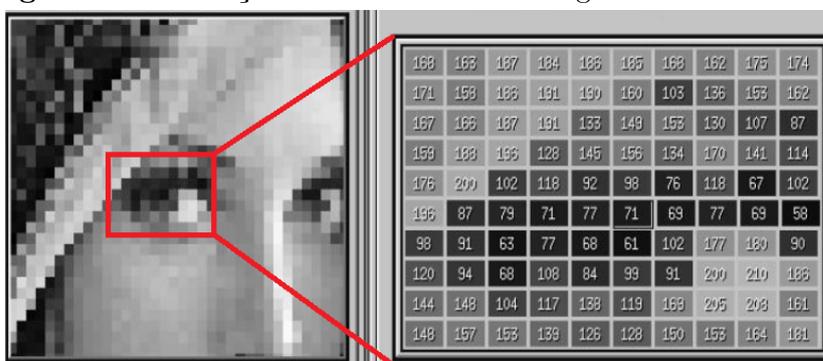
**Figura 9** – Variação de intensidade em imagens de tons de cinza.



Fonte: do autor.

cinza pode ser representada como uma matriz de inteiros, com valores que variam de 0 a 255, onde o ponto  $(x, y)$  representa a localização espacial do ponto na cena, e o valor dessa coordenada na matriz representa a quantização, em inteiros, do ponto da imagem. A Figura 10 mostra uma imagem e representação em matricial de uma região dessa imagem.

**Figura 10** – Variação de intensidade em imagens de tons de cinza.



Fonte: (GONZALEZ; WOODS; EDDINS, 2009).

Como pode ser visto na Figura 10, a imagem em tons de cinza contém apenas valores entre 0 e 255, sendo o 0 correspondente ao preto e o 255 ao branco.

### 3.1.1 Histograma

O histograma de uma imagem digital com níveis de intensidade no intervalo  $[0, L-1]$  é uma função discreta  $h(r_k) = n_k$  onde  $r_k$  é o  $k$ -ésimo valor de intensidade e  $n_k$  é o número de *pixels* da imagem com intensidade  $r_k$ .

Histogramas são utilizados em várias técnicas de processamento no domínio do espaço. A manipulação do histograma é bastante útil para o realce de imagens ou fornecimento de estatísticas. Através da visualização do histograma de uma imagem tem-se uma indicação qualitativa quanto ao nível de contraste e brilho. Cada termo do histograma normalizado é calculado conforme a Equação 3.1

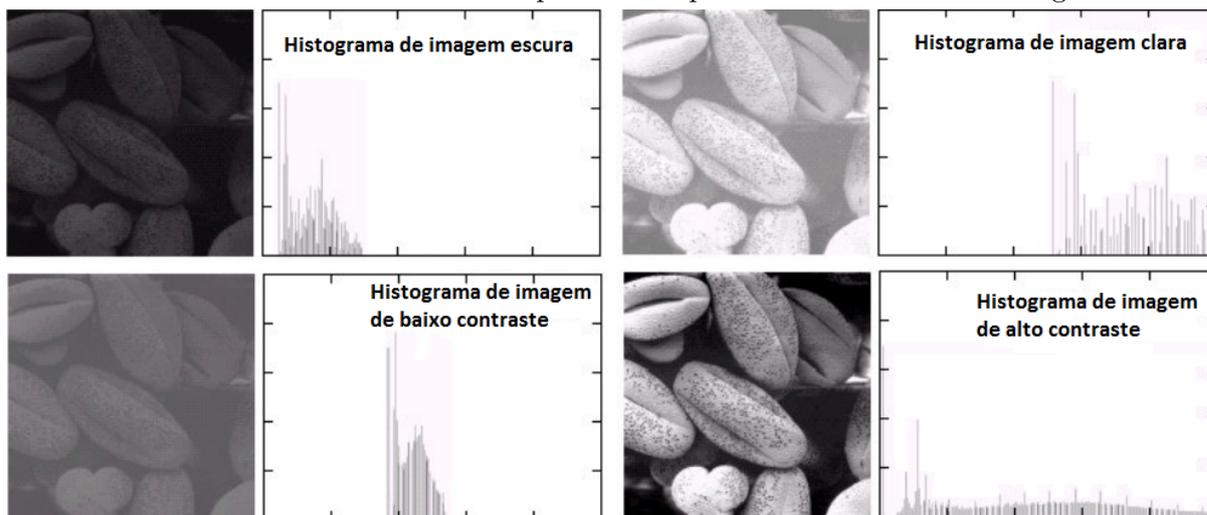
$$p_r(r_k) = \frac{n_k}{n}, \quad (3.1)$$

onde  $0 \leq r_k \leq L-1$ ,  $k \in [0, 1, 2, \dots, L-1]$ , sendo  $L$  o número de níveis de cinza da imagem, onde 0 representa o preto e  $L-1$  representa o branco, e  $n$  o número total de *pixels* da

imagem. A variável  $p_r(r_k)$  é a probabilidade ocorrência do nível de intensidade  $r_k$  e  $n_k$  é o número de *pixels* com intensidade  $r_k$ .

A Figura 11 mostra o histograma de imagens com diferentes tipos de contraste.

**Figura 11** – Quatro tipos básicos de imagem: escura, clara, baixo contraste, alto contraste e seus respectivos histogramas. O eixo horizontal corresponde aos níveis de tom de cinza (variando de 0 a 255) e o eixo vertical corresponde à frequência de cada nível na imagem.



Fonte: (GONZALEZ; WOODS; EDDINS, 2009).

A equalização do histograma consiste em ajustar a escala de tons de cinza de uma imagem para que os níveis de tons de cinza da imagem de entrada seja mapeada em um histograma uniforme. Desta forma, o objetivo da equalização do histograma é a obtenção de um histograma uniforme a partir de uma imagem inicial, permitindo um alto contraste, o que torna fácil a identificação dos elementos na imagem.

A equação de mapeamento de intensidade é descrita na Equação 3.2

$$s = T(r) = (L - 1) \sum_{j=0}^k p_r(r_j), 0 \leq k \leq L - 1, \quad (3.2)$$

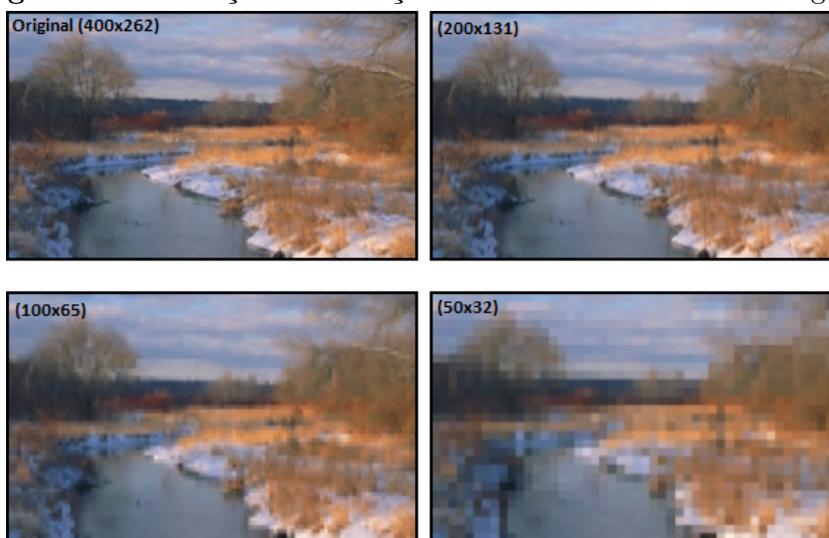
onde é produzido um nível de intensidade de saída  $s$  para todos os *pixels* da imagem de entrada que têm intensidade  $r_k$ . É assumido que  $T(r)$  é uma função monotonicamente crescente no intervalo de  $[0, L-1]$ , e  $T(r)$  assume valores entre 0 e  $L - 1$ . A primeira condição preserva a ordem da cor preta para o branco na escala de tons de cinza, e a segunda condição garante que a função seja consistente com o intervalo definido para os valores das intensidades dos *pixels*, no processo de equalização tradicional.

### 3.1.2 Resolução Espacial

A densidade de *pixels* em uma imagem é referida como resolução, em geral medida em pontos por polegadas (*dots per inch* - DPI). Quanto maior a resolução, mais informação contém a imagem. Caso se mantenha a imagem do mesmo tamanho e aumente a resolução, a imagem fica mais definida e mais detalhada. Desta forma, com uma resolução de imagem maior, pode-se produzir imagens maiores com a mesma quantidade de detalhes.

A Figura 12 mostra uma imagem com diferentes resoluções e com o mesmo tamanho. Em imagens de resolução menor, o nível de detalhe é menor. Logo, os *pixels* ficam maiores para manter o tamanho da imagem.

**Figura 12** – Variação de resolução com mesmo tamanho de imagem.



Fonte: (GONZALEZ; WOODS; EDDINS, 2009).

Quando se reduz a resolução da imagem, reduzindo o tamanho da imagem, se mantém a qualidade de detalhes. A Figura 13 mostra a redução de resolução mantendo o mesmo nível de detalhe por polegada.

**Figura 13** – Variação de resolução com tamanhos de imagens diferentes.

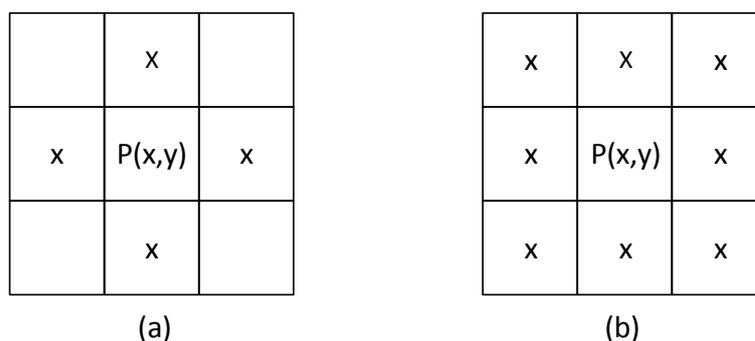


Fonte: (GONZALEZ; WOODS; EDDINS, 2009).

### 3.1.3 Vizinhança de um Pixel

Conforme descrito anteriormente, uma imagem digital possui uma representação matricial, onde os *pixels* estão distribuídos em uma grade uniformemente espaçada. Nesta grade, pode-se definir dois tipos de vizinhança: 4 conectada ou 8 conectada. Na vizinhança 4 conectada os vizinhos são equidistantes e considera-se apenas os *pixels* superior, inferior e laterais. Já na vizinhança 8 conectada considera-se também os *pixels* diagonais, porém estes são mais distantes do que os *pixels* laterais. A Figura 14 mostra os tipos de vizinhança.

**Figura 14** – Vizinhanças do *pixel*: (a) vizinhança 4; (b) vizinhança 8.



Fonte: do autor.

### 3.1.4 Medidas de Distância

Diversos algoritmos de processamento de imagens utilizam medidas de distância entre *pixels* em seu processamento. O cálculo das distâncias é baseado nas coordenadas dos *pixels*. A seguir, serão descritos dois tipos de medidas de distâncias: distância Euclidiana e distância quarteirão (*city block*), também chamada de  $D_4$ .

Dados os *pixels*  $p$  e  $q$ , com coordenadas  $(x, y)$  e  $(s, t)$ , respectivamente, a distância Euclidiana entre  $p$  e  $q$  é definida pela Equação 3.3

$$D_e(p, q) = \sqrt{(x - s)^2 + (y - t)^2}. \quad (3.3)$$

Para esta medida de distância, os *pixels* que têm uma distância menor ou igual a  $r$  de  $(x, y)$  são os pontos pertencentes a um círculo de raio  $r$  centralizado em  $(x, y)$ .

A distância  $D_4$  entre  $p(x, y)$  e  $q(s, t)$  é definida pela Equação 3.4.

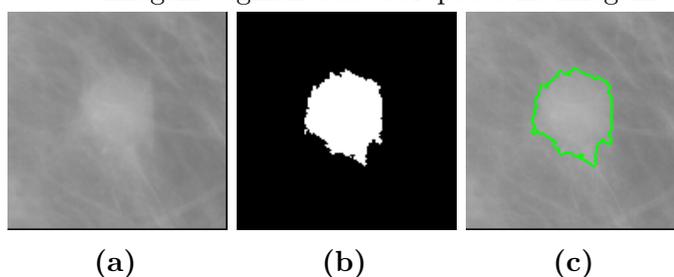
$$D_4(p, q) = |x - s| + |y - t|. \quad (3.4)$$

Neste caso, os *pixels* que têm uma distância  $D_4$  de  $(x, y)$  menor ou igual a um valor  $r$  formam um losango centralizado em  $(x, y)$ .

### 3.1.5 Segmentação

A segmentação é o processo de subdividir uma imagem em regiões ou objetos que a compõem. O nível de detalhe e região a ser segmentada depende do problema a ser resolvido. Em imagens de mamografia digital, por exemplo, o interesse do objeto a ser subdividido é a lesão. Uma vez separando o objeto de interesse do restante da imagem, fica mais fácil extrair suas características para posterior análise e diagnóstico. A Figura 15 mostra uma aplicação de segmentação para uma imagem de mamografia. A Figura 15 (a) mostra uma região com lesão, enquanto a Figura 15 (b) mostra a imagem segmentada. Para fins de visualização, muitas vezes é utilizada a representação da Figura 15 (c), onde é apresentado o contorno da imagem binarizada sobre a imagem original.

**Figura 15** – (a) Imagem Original. (b) Imagem Segmentada. (c) Contorno da imagem segmentada sobreposta na imagem original.



Fonte: do autor.

A segmentação pode seguir duas abordagens clássicas: descontinuidade e similaridade (NEVES; PELAES; SINAIS, 2008). Na segmentação por descontinuidade, a segmentação da imagem é efetuada com base nas alterações bruscas de intensidade, como por exemplo, em algoritmos de detecção de contornos, descritos por Papari e Petkov (2011). Na segmentação por similaridade a partição é efetuada com base na similaridade entre *pixels*. A seguir são descritos dois tipos de técnicas utilizadas para segmentação, as quais são utilizadas em algumas etapas do processo de segmentação das técnicas que serão vistas nesse documento.

### 3.1.6 Imagem Ouro

O termo imagem ouro, também chamado de padrão ouro, é utilizado no contexto de segmentação para se referir à imagem de segmentação esperada. Ela é uma imagem de referência para avaliar a qualidade de segmentação. No contexto de segmentação de lesões em imagem de mamografia, a imagem ouro é a imagem binarizada, contendo apenas a região da lesão, normalmente selecionada por um especialista. Desta forma, a imagem ouro serve para fins de comparação de algoritmos de segmentação, para avaliar a qualidade da segmentação obtida.

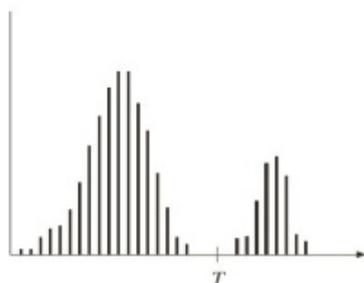
### 3.1.7 Limiarização

A limiarização consiste no processo de divisão de imagens diretamente em regiões com base nos valores de intensidade e/ou na propriedade desses valores. A limiarização em regiões de fundo e objeto também é chamada de binarização. O objetivo é rotular o fundo com um valor, e as informações do primeiro plano com outro valor, normalmente branco e preto, gerando uma imagem binária.

Supondo que o histograma de intensidade da Figura 17 corresponda a uma imagem,  $f(x, y)$ , composta por objetos claros sobre um fundo escuro de tal forma que os *pixels* do objeto e do fundo tenham valores de intensidade agrupados em dois grupos dominantes. Uma maneira simples de extrair os objetos do fundo é selecionar um limiar  $T$ , que separa esses dois grupos. Desta forma, a imagem pode ser segmentada de acordo a Equação 3.5.

$$g(x, y) = \begin{cases} 1, & f(x, y) > T \\ 0, & f(x, y) \leq T \end{cases} \quad (3.5)$$

**Figura 17** – Histograma de intensidade dividido por um limiar único. Eixo horizontal: níveis de tom de cinza. Eixo vertical: frequência.



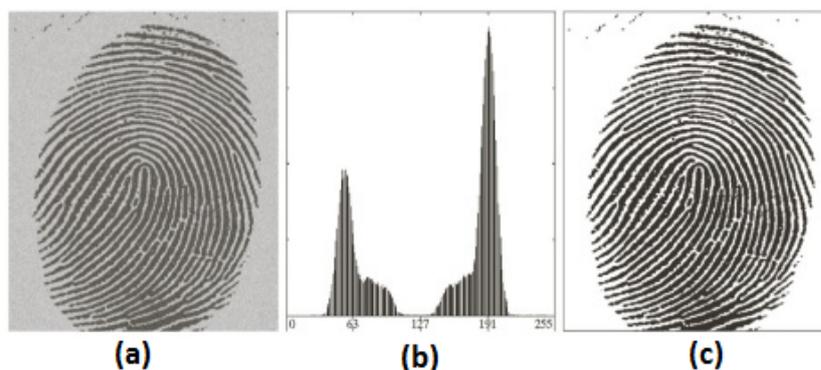
Fonte: (GONZALEZ; WOODS; EDDINS, 2009).

Quando  $T$  é uma constante aplicável a uma imagem inteira, o processo dado nesta equação é conhecido como limiarização global. A Figura 18 mostra um processo de limiarização global para segmentar uma imagem de impressão digital.

A limiarização global é eficiente apenas quando têm-se regiões bem distintas no histograma de uma imagem, ou seja, objeto e fundo pertencem a regiões distintas no histograma. Em imagens de mamografia digital, por exemplo, é difícil separar imagens da região de tecido e da lesão, pois a tonalidade do tecido muitas vezes se iguala à do lesão.

Quando o valor de limiar  $T$  muda ao longo da imagem, baseado em propriedade de uma vizinhança de  $(x, y)$ , usa-se o termo limiarização local ou regional. Se  $T$  depende das coordenadas espaciais  $(x, y)$  como tal, então a limiarização é chamada de dinâmica ou adaptativa.

**Figura 18** – (a) Impressão digital ruidosa. (b) Histograma. (c) Segmentação resultante usando um limiar global.



Fonte: (GONZALEZ; WOODS; EDDINS, 2009).

Uma abordagem de limiarização global bastante utilizada é o método de Otsu (GONZALEZ; WOODS; EDDINS, 2009). Esse método maximiza a variância entre classes na atribuição de *pixels* para dois ou mais grupos, também chamados de classes. O método baseia-se na ideia de que as classes devem ser distintas em relação aos valores de intensidade de seus *pixels* e que um limiar que oferece a melhor separação entre as classes em termos de valores de intensidade seria o melhor limiar, também chamado de limiar ótimo. Para isso, o método de Otsu baseia-se inteiramente em cálculos realizados no histograma de uma imagem. Para aplicar o método de Otsu, inicialmente é necessária a normalização do histograma. Para um determinado limiar  $T$ , divide-se os *pixels* da imagem em duas classes:  $C_1$  e  $C_2$ , sendo o grupo da classe  $C_1$  formado pelos valores  $0, 1, 2, \dots, T-1$  e o grupo  $C_2$  formado pelos valores  $T, T+1, \dots, L-1$ . A variância entre classes, representada por  $\sigma_B^2$ , é definida na Equação 3.6.

$$\sigma_B^2 = w_1(\mu_1 - \mu_T)^2 + w_2(\mu_2 - \mu_T)^2, \quad (3.6)$$

$$w_1 = \sum_{k=0}^{T-1} p_r(r_k), \quad (3.7)$$

$$w_2 = \sum_{k=T}^{L-1} p_r(r_k), \quad (3.8)$$

onde  $\sigma_B^2$  é a variância,  $w_1$  é a probabilidade do grupo  $C_1$ ,  $w_2$  é a probabilidade do grupo  $C_2$ ,  $\mu_1$  é a média de intensidade dos *pixels* do grupo  $C_1$ ,  $\mu_2$  é a média de intensidade do grupo  $C_2$ ,  $k$  é o nível de cinza,  $\mu_T$  é a média total do histograma e  $p_r(r_k)$  é o percentual do  $k$ -ésimo nível de cinza. O método de Otsu consiste em encontrar o limiar ótimo variando o limiar de forma a maximizar o valor de  $\sigma_B^2$ .

### 3.1.8 Segmentação Baseada em regiões

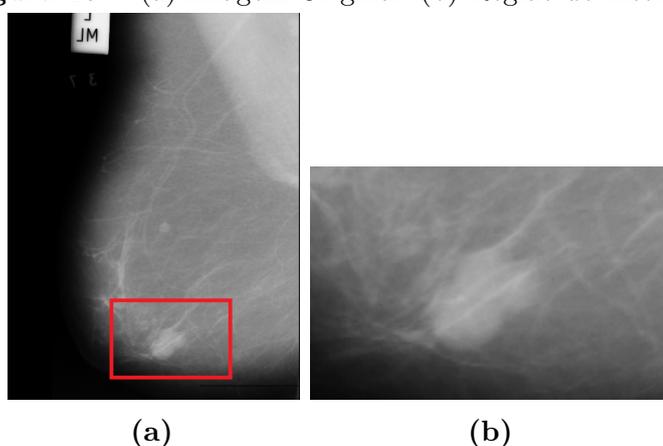
Segundo Dhaliwal e Jain (2013), em segmentações baseadas em regiões, normalmente o processo é inicializado com um conjunto de *pixels* semente, aos quais vão sendo adicionados mais *pixels* pertencentes à região de acordo com um critério pré-estabelecido.

O critério de aumento de região é específico de cada problema e técnica, podendo ser baseado na intensidade dos *pixels* ou na região de vizinhança. Também é necessário definir um critério de parada, que pode ser o algoritmo convergir ou um número máximo de iterações. Uma das desvantagens desse método é que a segmentação pode depender da localização das sementes iniciais.

### 3.1.9 Região de Interesse

Selecionar uma região de interesse (*region of interest*, ROI) a partir de uma imagem digital consiste em selecionar uma região que contenha um objeto a ser segmentado. Em problemas difíceis de segmentar, tais como a segmentação de lesões em imagens de mamografia (ZEWEI et al., 2014), muitas vezes o usuário seleciona uma região de interesse para depois aplicar um algoritmo de segmentação. A Figura 19 mostra a seleção de uma região de interesse a partir de uma imagem de mamografia.

**Figura 19** – (a) Imagem Original. (b) Região de Interesse.



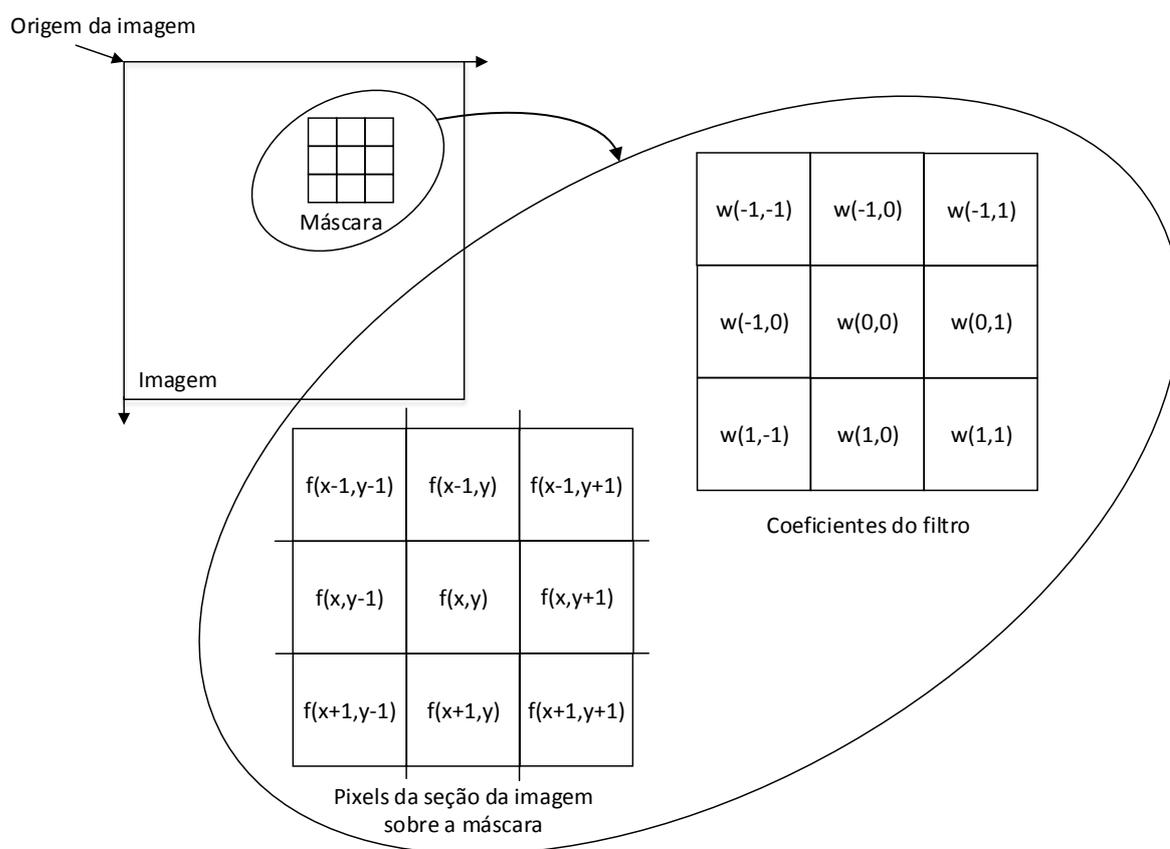
Fonte: (SUCKLING et al., 1994)

### 3.1.10 Filtros

A filtragem consiste na utilização de operações com fins de realce de imagem ou redução de ruídos (GONZALEZ; WOODS; EDDINS, 2009). Normalmente é uma etapa de pré-processamento para aplicação de algum algoritmo de processamento de imagem. Nessa seção, serão vistos alguns filtros no domínio espacial, que se refere ao próprio plano da imagem e na manipulação direta dos *pixels* que a compõem. As técnicas de filtragem consistem na aplicação de uma máscara de filtro em cada ponto da imagem  $(x, y)$ , sendo a

resposta do filtro em cada ponto calculada utilizando relações pré-definidas. Deste modo, a aplicação destes operadores locais consiste na definição de um ponto central  $(m, n)$ , na execução de uma operação que envolve apenas os *pixels* numa vizinhança pré-definida em torno do ponto central, sendo o resultado dessa operação a resposta do processo e o valor a ser escrito no *pixel*  $(m, n)$  da imagem filtrada. Este processo é repetido para cada *pixel* da imagem. A Figura 21 ilustra o funcionamento da filtragem espacial utilizando uma vizinhança 3x3.

**Figura 21** – Funcionamento da filtragem espacial utilizando uma máscara 3x3.



Fonte: (GONZALEZ; WOODS; EDDINS, 2009).

Em qualquer ponto  $(x,y)$  da imagem, a resposta  $g(x,y)$  do filtro linear é a soma dos produtos dos coeficientes do filtro com os *pixels* da imagem englobados pelo filtro, de acordo com a Equação 3.9. O coeficiente central do filtro,  $w(0,0)$ , se alinha com o *pixel* da posição  $(x, y)$ .

$$g(x, y) = w(-1, 1) \cdot f(x - 1, y - 1) + w(-1, 0) \cdot f(x - 1, y) + \dots + w(0, 0) \cdot f(x, y) + \dots + w(1, 1) \cdot f(x + 1, y + 1). \quad (3.9)$$

### 3.1.10.1 Filtro de Média

O filtro de média é um dos filtros lineares mais simples e é utilizado para suavização e redução de ruídos. Esse filtro consiste em uma operação local de média onde o valor de cada *pixel* é substituído pela média de todos os valores na sua vizinhança local. A ideia por trás desse filtro é que ao substituir o valor de cada *pixel* de uma imagem pela média dos níveis de intensidade da vizinhança definida pela máscara, o processo resulta em uma imagem com perda de nitidez, ou seja, perda de transições altas na intensidade. Pelo fato de o ruído aleatório normalmente consistir em transições abruptas nos níveis de intensidade, a aplicação mais evidente é a redução de ruído.

### 3.1.10.2 Filtro de Mediana

Os filtros de mediana (GONZALEZ; WOODS; EDDINS, 2009) também são bastante utilizados, pois para ruídos do tipo aleatório proporcionam bons resultados, com borramento consideravelmente menor do que filtros lineares de suavização de tamanho similar (GONZALEZ; WOODS; EDDINS, 2009). Esse tipo de filtro é útil na remoção de *pixels* ou linhas isolados, preservando a resolução espacial da imagem. O filtro de mediana, como o nome sugere, substitui o valor de um *pixel* pela mediana dos valores de intensidade na vizinhança desse *pixel* (o valor do *pixel* é incluído no cálculo da mediana). Para calcular a filtragem por mediana numa vizinhança de um *pixel*  $P$ , deve-se selecionar o valor do *pixel* e dos seus vizinhos, após isso determinar a mediana e finalmente atribuir o valor da mediana ao equivalente  $P$  na imagem resultante.

### 3.1.10.3 Filtro Laplaciano

O filtro Laplaciano (GONZALEZ; WOODS; EDDINS, 2009) é um operador diferencial, onde sua utilização realça as descontinuidades de intensidade em uma imagem e atenua as regiões com níveis de intensidade de variação mais suave. Isso tenderá a produzir imagens nas quais as linhas de borda e outras descontinuidades aparecerão em tons de cinza sobrepostos a um fundo escuro e uniforme. As características do fundo podem ser recuperadas enquanto se preserva o efeito de aguçamento Laplaciano simplesmente adicionando a imagem Laplaciana à original. A forma de utilizar o filtro Laplaciano para o aguçamento de imagens é definido pela Equação 3.10.

$$g(x, y) = f(x, y) - [\nabla^2 f(x, y)], \quad (3.10)$$

$$\nabla^2 f = f(x + 1, y) + f(x - 1, y) + f(x, y + 1) + f(x, y - 1) - 4f(x, y), \quad (3.11)$$

onde  $f(x,y)$  e  $g(x,y)$  são as imagens de entrada e aguçada respectivamente.

### 3.1.11 Descritores de Imagem

A partir de uma imagem digital pode-se extrair atributos da imagem a fim de identificar alguma propriedade ou elemento contido na imagem. Os atributos de uma imagem são informações numéricas, provenientes de análise da composição dos *pixels*, que podem ajudar na identificação da presença de um objeto na imagem, tal como uma lesão em uma imagem de mamografia.

A extração dessas características pode ser aplicada à imagem toda, para extrair informação de textura, por exemplo, ou para regiões de objetos, tais como área, perímetro e forma de uma região segmentada. Normalmente essa extração é realizada por descritores, os quais podem extrair características quanto à forma ou textura, por exemplo. Normalmente esses descritores apresentam propriedades invariantes à rotação e escala, o que permite que mesmo se o objeto estiver em uma escala menor ou rotacionado, o valor do descritor será o mesmo. A seguir são descritos os Momentos de Zernike, que são descritores de imagens aplicados neste trabalho.

#### 3.1.11.1 Momentos de Zernike

Os Momentos de Zernike (TAHMASBI; SAKI; SHOKOUHI, 2011) são descritores de imagem em relação à forma e à margem. Esses descritores são invariantes à rotação, são não redundantes e são robustos à ruídos aleatórios e à forma (WANG; MOTTERSHEAD; MARES, 2009). Os operadores de Zernike são divididos em 64 descritores, chamados de momentos, os quais são divididos em momentos de baixa e alta ordem.

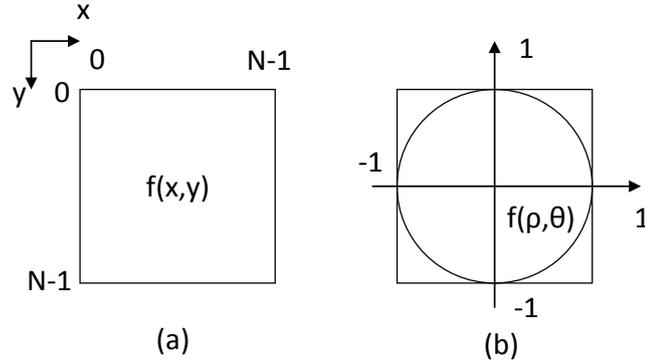
Os Momentos de Zernike têm sido aplicados com sucesso para identificação de lesões em imagens de mamografia (TAHMASBI; SAKI; SHOKOUHI, 2011). Isso mostra que uma vez obtida uma boa segmentação, a aplicação dos Momentos de Zernike é adequada para realizar a classificação sobre o tipo de lesão. Logo, a qualidade da segmentação também pode ser avaliada baseado no resultado da classificação, utilizando os Momentos de Zernike.

Os momentos de Zernike são definidos como projeções da função de intensidade da imagem, representada por  $f(x, y)$ , sobre funções de bases ortogonais, que são os polinômios de Zernike. Esses polinômios formam um conjunto ortogonal complexo no interior de um círculo unitário, sendo limitado pela curva  $x^2 + y^2 = 1$ . A Figura 22 mostra o mapeamento da imagem digital sendo mapeada para as coordenadas polares.

O cálculo dos momentos de Zernike para uma imagem digital  $f(x, y)$ , é dada pela Equação 3.12:

$$Z_{n,m} = \frac{n+1}{\pi(N-1)} \sum_{x=1}^N \sum_{y=1}^N f(x,y) V_{n,m}(\rho, \theta), \quad (3.12)$$

**Figura 22** – (a) Imagem digital  $N \times N$  e (b) imagem mapeada em um círculo unitário.



Fonte: do autor.

onde  $\rho = \frac{\sqrt{x^2+y^2}}{N}$  e  $\theta = \tan^{-1}(y/x)$ . A variável  $n$  é um número natural denominado ordem do momento e  $m$  é um inteiro positivo ou negativo, denominado repetição, que satisfaz a restrição  $n - |m| = 2k, k \in \mathbb{Z}$ , e  $|m| \leq n$ . A variável  $V_{n,m}$  é a família de polinômios de Zernike, definida pelas equações 3.13 e 3.14.

$$V_{n,m}(\rho, \theta) = R_{n,m}(\rho)^{-jm\theta}, \quad (3.13)$$

$$R_{n,m} = \sum_{s=0}^{(n-|m|)/2} (-1)^s \frac{(n-s)!}{s!(((n+|m|)/2)-s)!(((n-|m|)/2)-s)!} \rho^{n-2s}. \quad (3.14)$$

Para calcular os momentos de Zernike de uma imagem, o centro dela é considerado como o centro do disco unitário e as coordenadas do *pixel* são mapeadas para esse disco. Os momentos de Zernike são divididos em 64 descritores, agrupados em dois grupos de 32, definidos como momentos de baixa ordem e de alta ordem. A Tabela 1 mostra os valores de  $m$  e  $n$  para a geração dos descritores de cada grupo, onde o grupo 1 e 2 representam os momentos de baixa e alta ordem, respectivamente.

### 3.1.11.2 Descritores de Haralick

Os descritores de Haralick (HARALICK; SHANMUGAM; DINSTEIN, 1973) são descritores de imagem bastante utilizados na literatura e que também têm sido aplicados para detecção de lesões em imagens de mamografia (JENIFER; PARASURAMAN; KADIRVEL, 2014). Os descritores de Haralick são compostos por 13 descritores relacionados às características da imagem conforme descrito na Tabela 2.

Os descritores de Haralick descrevem características baseados em texturas realizado a partir de cálculos estatísticos entre pixels vizinhos, que definem características obtidas

**Tabela 1** – Momentos de Zernike utilizados.

Grupo	n	m	Número de Momentos
1	3	1, 3	32
	4	0, 2, 4	
	5	1, 3, 5	
	6	0, 2, 4, 6	
	7	1, 3, 5, 7	
	8	0, 2, 4, 6, 8	
	9	1, 3, 5, 7, 9	
10	0, 2, 4, 6, 8, 10		
2	10	2, 6, 10	32
	11	3, 7, 11	
	12	0, 4, 8, 12	
	13	1, 5, 9, 13	
	14	2, 6, 10, 14	
	15	3, 7, 11, 15	
	16	0, 4, 8, 12, 16	
17	1, 5, 9, 13, 17		

**Tabela 2** – Descritores de Haralick usados para extração de características.

Número	Característica
1	Energia ou Uniformidade
2	Contraste
3	Correlação
4	Soma de Variância
5	Momento da Diferença Inversa
6	Média da Soma
7	Variância da Soma
8	Entropia da Soma
9	Entropia
10	Variância da Diferença
11	Entropia da Diferença
12	Medida de Informação de Correlação 1
13	Medida de Informação de Correlação 2

através de uma matriz de co-ocorrência, os quais são descritos na Tabela 55, no Apêndice C. A matriz de co-ocorrência possui os valores de ocorrência de cores em uma determinada imagem. Essas características são utilizadas para diferenciar texturas que não seguem um padrão de repetição.

### 3.2 CONCEITOS DE INTELIGÊNCIA COMPUTACIONAL

Nesta seção, serão descritos alguns fundamentos de inteligência artificial, explicando alguns termos que serão utilizados ao longo deste documento. Muitos algoritmos de processamento de imagem incorporam técnicas de inteligência artificial para fins de otimização ou para reconhecimento de padrões. No entanto, como essa é uma área bastante

ampla, nessa seção serão citados apenas alguns conceitos necessários para o entendimento das técnicas apresentadas nesse documento.

### 3.2.1 Classificadores

O uso de classificadores, como o próprio nome diz, é utilizado para classificar elementos ou objetos de um conjunto, separando-os em diferentes classes ou categorias. Para isso, são utilizadas características associadas ao objeto a ser classificado, que servem como entrada para o classificador, e este fornece uma saída, que é o rótulo do objeto. O uso de classificadores associados à imagem digital pode ser utilizado para classificar um objeto segmentado a partir dos atributos extraídos da imagem. No caso da classificação em mamografia digital, o classificador pode ser usado para identificar o tipo de lesão, baseados nas características de forma do objeto segmentado.

Existem vários classificadores bastante validados na literatura, inclusive usado para classificação de lesões em imagens de mamografia, tais como o classificador Bayesiano (KARABATAK, 2015), *Multilayer Perceptron* (MLP) (KRUSE et al., 2013) e *Support Vector Machines* (SVM) (GORGEL et al., 2012). Estes classificadores possuem duas etapas no processo classificação de objetos: a etapa de treinamento, em que é realizado o aprendizado sobre as características do problema, e a etapa de teste, onde é averiguado o desempenho do classificador. Durante o treinamento, é realizado o aprendizado do processo de classificação dos dados a partir das entradas e saídas fornecidas pelo usuário. Na etapa de teste é realizada predição dos dados de entrada e validado a eficiência do classificador. O algoritmo MLP, que é um classificador bastante validado na literatura, está descrito no Apêndice C.

### 3.2.2 Tipos de Aprendizado

O aprendizado é dito supervisionado, quando existe algum tipo de informação sobre o o estado do ambiente (entrada) e as ações do sistema (saída). Em um sistema de aprendizado supervisionado por um instrutor, existe um conjunto de treinamento contendo pares de entrada e saída do sistema, fornecidos pelo instrutor. Desta forma, o algoritmo de aprendizado recebe um conjunto de exemplos de treinamento para os quais os rótulos da classe associadas são conhecidos. Cada exemplo (instância ou padrão) é descrito por um vetor de valores (atributos) e pelo rótulo da classe associada (CHAPELLE et al., 2006). Como exemplo, na classificação de imagens, são fornecidos na etapa de treinamento as características da imagem e a classe à qual ela pertence.

Na aprendizagem não supervisionada, os dados apresentados ao algoritmo não são rotulados. O objetivo é aprender a estrutura dos dados apresentados. Em um aprendizado não-supervisionado, ele ocorre apenas através das observações dos estados do ambiente, sem conhecimento prévio. Segundo Russell e Norvig (2003), nessa forma de aprendizado, o

sistema reconhece padrões nos dados de entrada, mesmo sem nenhuma informação se a saída está correta ou não, agrupando elementos com características similares.

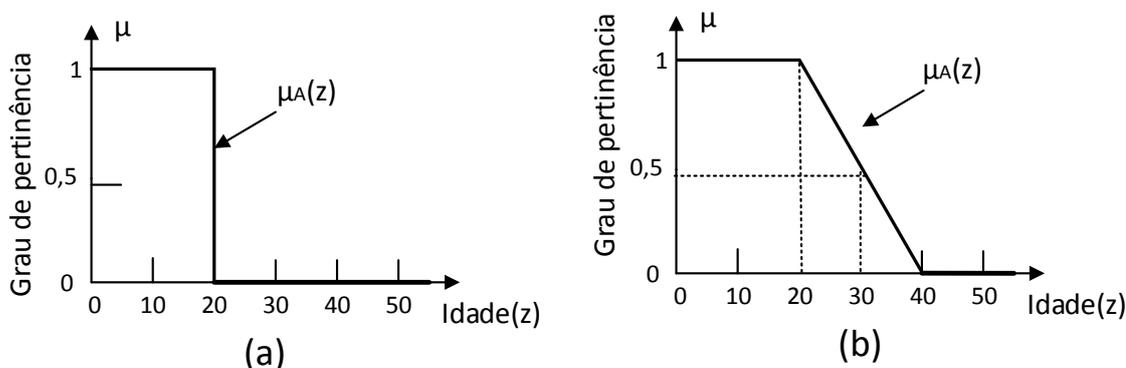
Além dos paradigmas de aprendizagem já citados, existe outro paradigma chamado aprendizagem semi-supervisionada. Segundo Chapelle et al. (2006), em um método semi-supervisionado é fornecido algum tipo de informação supervisionada, mas não necessariamente para todos os exemplos. Esses algoritmos podem ser uma adaptação de um algoritmo supervisionado, que vai levar em conta exemplos não rotulados na aprendizagem. No trabalho proposto é apresentado um método semi-supervisionado, o que indica que uma parte do método requer o conhecimento prévio, que é a seleção da região de interesse onde está localizada a lesão, e o restante do procedimento é realizado automaticamente apenas com as observações da região de interesse.

### 3.2.3 Lógica Fuzzy

Segundo Rajasekaran e Pai (2011), a lógica *fuzzy*, também chamada de lógica difusa ou nebulosa, é uma extensão da lógica booleana que permite valores de pertinência intermediários entre 0 e 1.

A teoria clássica dos conjuntos permite o tratamento de classes de objetos e suas inter-relações em um universo definido. Nessa teoria, a pertinência de um dado elemento a um conjunto refere-se ao fato de tal elemento pertencer ou não a esse conjunto. Na teoria clássica dos conjuntos, a pertinência só pode ser verdadeira ou falsa no sentido tradicional da lógica booleana de dois valores, com 1 normalmente indicando verdadeiro e 0 indicando falso. A Figura 23 (a) resume esse conceito, como um exemplo de alto nível, utilizando um limiar de idade de 20 e com  $\mu_A(z)$  expressando a função de pertinência no conjunto dos adultos.

**Figura 23** – Funções de pertinência do ponto de vista da (a) lógica convencional e (b) da lógica fuzzy.



Fonte:(GONZALEZ; WOODS; EDDINS, 2009).

Na Figura 23 (a), que representa a lógica booleana, o grau de pertinência varia apenas em 0 ou 1, separando as pessoas com idade maior que 20 anos e menor ou igual em duas classes. Já na Figura 23 (b), que representa a lógica *fuzzy*, o grau de pertinência assume valores entre 0 e 1 para as idades entre 20 e 40 anos, o que mostra que nessa região não é assumido que o elemento pertence completamente ao conjunto, mas sim que há um grau de pertinência que pode variar nesse intervalo.

Na lógica *fuzzy* os elementos têm graus de pertinência aos conjuntos *fuzzy* definidos, que podem variar de 0 a 1. Ao contrário da lógica convencional, a lógica *fuzzy* utiliza a ideia de que elementos de um universo admitem graus de pertinência a um dado conjunto. A Figura 23 (b) mostra os níveis de pertinência em relação à função de pertinência, que varia gradativamente.

Apesar de a probabilidade e a lógica *fuzzy* operarem no mesmo intervalo [0,1], é importante distinguir a diferença entre as duas. No exemplo da Figura 23 (b), uma afirmação probabilística seria dizer que “existe 50% de chance de uma pessoa de 30 anos ser jovem”, enquanto que na lógica *fuzzy* seria que “o grau de pertinência de uma pessoa dentro do conjunto de pessoas jovens é de 0,5” (GONZALEZ; WOODS; EDDINS, 2009). Na primeira afirmação, uma pessoa é considerada como parte do conjunto de pessoas jovens ou do conjunto de pessoas não jovens, onde temos 50% de chance de sabermos a qual conjunto a pessoa pertence. Já na segunda afirmação a pessoa é jovem em algum nível, que no caso é de 0,5. Em outras palavras, a lógica *fuzzy* não é probabilística; ela só lida com graus de pertinência em um conjunto (GONZALEZ; WOODS; EDDINS, 2009).

Desta forma, enquanto a tomada de decisão na teoria clássica pode ser representada pela Equação 3.15, a da lógica *fuzzy* pode ser representada pela Equação 3.16, considerando um conjunto  $A$  e um elemento  $x$  com relação a esse conjunto.

$$f(x) = \begin{cases} 1, & x \in A \\ 0, & x \notin A \end{cases}, \quad (3.15)$$

$$\mu(x) = \begin{cases} 1, & x \in A \\ 0, & x \notin A \\ 0 \leq \mu(x) \leq 1, & x \text{ pertence parcialmente a } A \end{cases}. \quad (3.16)$$

Como pode ser observado na Equação 3.16, o intervalo de pertinência é [0,1], onde 0 significa que um elemento não pertence a um determinado conjunto, 1 significa completa pertinência ao conjunto e valores entre 0 e 1 representam graus parciais de pertinência. Assim, na lógica *fuzzy*, um elemento pertence a um conjunto com um certo grau de pertinência, fazendo com que uma determinada característica possa ser parcialmente verdadeira ou parcialmente falsa. Além disso, um mesmo elemento pode ter graus de pertinências diferentes de 0 para mais de um conjunto *fuzzy*. A modelagem é realizada

utilizando funções de pertinência, que mapeiam os elementos do conjunto atribuindo níveis de pertinência. Entre as funções de pertinência estão a triangular, trapezoidal e gaussiana (GONZALEZ; WOODS; EDDINS, 2009).

### 3.2.4 Algoritmos de Otimização

Algoritmos de otimização foram desenvolvidos para resolver problemas caracterizados pela dificuldade de encontrar soluções ótimas em um grande espaço de busca: chamados de problemas de otimização. Nesse tipo de problema é inviável testar todos os parâmetros possível devido ao grande espaço de exploração. As características a serem otimizadas são chamadas de objetivos, e muitas vezes esses objetivos competem entre si. Por exemplo, ao se comprar um carro deseja-se que ele tenha um bom desempenho e um baixo consumo de combustível. Para esse caso os objetivos a serem otimizados são desempenho e consumo. Mas normalmente quanto maior o desempenho, menor o consumo, e vice versa. Nesse problema, poderiam se considerar parâmetros o motor, peso, tamanho, etc. Exemplos de áreas de aplicação são: roteamento de redes de computadores, sistemas embarcados, mineração de dados e processamento de imagens, conforme apresentado por Dasgupta e Michalewicz (2013).

Normalmente, em algoritmos de otimização é definida uma função de avaliação, também chamada de função *fitness* ou função de aptidão, e é utilizada para medir o grau de aptidão das soluções encontradas (ZHOU et al., 2011). A função *fitness* serve para medir a qualidade da solução, e a forma como ela é calculada pode influenciar na eficiência do algoritmo.

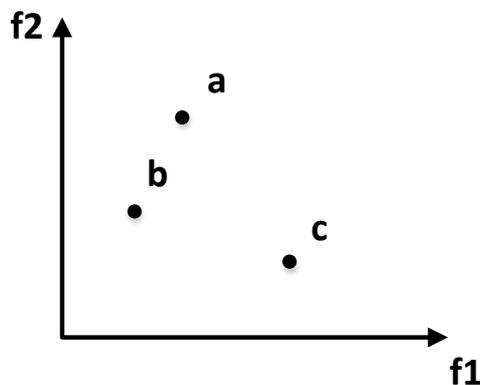
Vários problemas de otimização existentes envolvem mais de um objetivo a serem otimizados, sendo chamados de problemas de otimização multi-objetivo (MOP) (ZHOU et al., 2011). Desta forma, a busca por soluções ótimas no espaço de exploração deve visar atender todos os objetivos simultaneamente. No entanto, na maioria dos casos isso não é possível devido a conflitos e restrições entre os objetivos a serem otimizados.

Problemas de otimização multi-objetivo (MOO) (ALI; SIARRY; PANT, 2012) são caracterizados pela dificuldade em encontrar uma solução que satisfaça simultaneamente todos os objetivos, sendo necessário muitas vezes penalizar alguns objetivos para se encontrar uma solução mais adequada ao problema. Por essa razão, é comum realizar a busca por um conjunto de soluções mais viáveis ao problema, ao invés de apenas uma, deixando a decisão de escolher a solução ser tomada de acordo com o nível de prioridade de cada objetivo.

O conceito de dominância é bastante utilizado em algoritmos multi-objetivos e serve para indicar e comparar o grau de qualidade de uma solução em relação à outra. Diz-se que uma solução *a* domina *b*, se, e somente se, para todos os objetivos envolvidos no domínio da função, *a* não for pior que *b* em nenhum objetivo e existir pelo menos um

objetivo em que  $a$  seja melhor que  $b$ . A Figura 24 ilustra a relação de dominância entre diferentes pontos do conjunto de solução, para um problema de minimização dos objetivos  $f_1$  e  $f_2$ .

**Figura 24** – Relação de dominância entre soluções, em um problema de minimização.



Fonte: do autor.

Em uma otimização multi-objetivo, o objetivo é encontrar o conjunto de soluções ótimas que tenha a melhor relação entre os objetivos a serem otimizados. O conjunto das melhores soluções do espaço de exploração que são equivalentes entre si em termos de qualidade de solução está localizada na região chamada de *Pareto Optimal* (DEB, 2014). Porém, o conjunto das melhores soluções encontradas pelo algoritmo de otimização é chamado de *Pareto Front*. Desta forma, a meta principal de um algoritmo de otimização multi-objetivo é fazer com que o *Pareto Front* seja o mais próximo possível do *Pareto Optimal*, com o menor custo computacional.

Técnicas de otimização multi-objetivo (ALI; SIARRY; PANT, 2012) são aplicadas em diversas áreas onde existe um grande espaço de busca e se deseja encontrar uma determinada configuração ótima explorando apenas uma pequena região do espaço de exploração. Exemplos de áreas de aplicação são: roteamento de redes de computadores, sistemas embarcados, mineração de dados e processamento de imagens. Em diversas áreas os resultados encontrados por essas técnicas têm sido bastante satisfatórios. No entanto existem técnicas que são melhores para determinados tipos de problemas e existem diferentes formas de configurar os parâmetros de cada técnica. Portanto, em alguns casos é interessante testar diferentes métodos de otimização, com variações de parâmetros, de forma a identificar a melhor abordagem de otimização para o problema a ser tratado (DEB, 2014).

No exemplo da Figura 24, existem pontos que compõem o conjunto de soluções encontradas:  $a$ ,  $b$  e  $c$ . De acordo com a definição, pode-se dizer que a solução  $b$  domina  $a$ , pois ela é melhor que  $a$  em pelo menos um objetivo, no caso o objetivo  $f_1$ , e também não é pior que em nenhum deles. De forma análoga, não se pode dizer que a solução  $b$  domina  $c$ ,

pois a solução  $b$  é pior que  $c$  em pelo menos um objetivo, no caso  $f_2$ . Dessa forma, pode-se dizer que  $b$  domina  $a$ , mas não domina  $c$ . Com esse conceito, pode-se dizer também que  $a$  não domina  $c$ , pois existe pelo menos um objetivo em  $a$  que é pior que em  $c$ . O mesmo vale para afirmar que  $c$  não domina  $a$ . Esta relação em que uma solução não é dominada por outra é chamada de não-dominância. Normalmente costuma-se dizer que uma solução é não-dominada como sendo aquela que apresenta uma relação de não-dominância com todas as outras soluções do conjunto de soluções.

### 3.3 CONSIDERAÇÕES DO CAPÍTULO

Neste capítulo foram apresentados diferentes fundamentos de processamento de imagem e inteligência computacional. Espera-se que os conceitos apresentados auxiliem a compreensão das técnicas utilizadas no estado da arte e no entendimento da metodologia aplicada no algoritmo proposto.

## 4 TRABALHOS RELACIONADOS

Este capítulo tem como objetivo apresentar o estado da arte em relação à segmentação de lesões em imagens de mamografia digital. Neste capítulo serão descritas as principais contribuições desenvolvidas nos últimos anos, citando as principais contribuições e características que permitiram o desenvolvimento de técnicas de segmentação de lesões. Além disso, são apresentados os algoritmos e comparação das principais técnicas relacionadas no estado da arte.

### 4.1 ESTADO DA ARTE

Tendo em vista o impacto de uma boa segmentação no auxílio ao diagnóstico médico, muitos trabalhos têm sido realizados a fim de facilitar esse processo e torná-lo mais confiável. Existem três tipos básicos de trabalhos voltados para o auxílio e diagnóstico na detecção de câncer de mama: pré-processamento, segmentação e classificação.

#### 4.1.1 Pré-processamento

O pré-processamento de imagens de mamografia digital é utilizado frequentemente com a finalidade de melhorar o contraste ou eliminar ruídos da imagem, a fim de facilitar a identificação da lesão para o profissional ou para alguma técnica de segmentação. Isso muitas vezes é necessário devido a dois fatores: a baixa qualidade de imagem que alguns equipamentos fornecem, com ruídos ou baixo contraste, o que dificulta uma análise mais aprofundada sobre a imagem, e a variabilidade de equipamentos, com parâmetros distintos, que causa maior irregularidade nas imagens obtidas.

As técnicas de pré-processamento convencionais são utilizadas para melhorar a visualização da lesão, normalmente através de uma equalização do histograma. Rahmati et al. (2010) propõe o algoritmo de pré-processamento chamado de FCLAHE, que se baseia em uma técnica de equalização do histograma com limiar adaptativo aplicando lógica *fuzzy*. A vantagem do FCLAHE é que ele consegue a eliminação dos ruídos da imagem e mantém o contraste das regiões de lesão da mama, o que melhora a identificação dos objetos de interesse da imagem. Sundaram et al. (2011) propõem uma modificação no algoritmo HM-LCE, que é uma técnica local de melhoria de contraste baseada em histograma, tornando mais forte o contraste e trazendo detalhes presentes na imagem original para uma melhora na interpretação da mamografia. Tortajada et al. (2014) realiza equalização da região periférica da mama, realçando as lesões contidas nessa região.

As técnicas de pré-processamento baseadas em região, como o próprio nome diz, se baseiam nas regiões vizinhas para melhorar a visibilidade das lesões. Jain, Singh e Bhateja

(2013) propuseram uma técnica de redução de ruído e aumento de contraste baseado em estatística da região para melhorar o contraste das imagens de mamografia analisadas. Bhateja et al. (2013) propõem um algoritmo de filtragem que se sobressai no aumento de contraste de regiões com lesão.

Um terceiro tipo de técnica de pré-processamento são as técnicas baseadas nas características da imagem. Esses tipos de técnicas analisam as características de uma região da imagem e comparam com as características de uma região de lesão. Essa abordagem também pode ser utilizada para identificar calcificações, utilizando as propriedades desse tipo de lesão. Karahaliou et al. (2014) propõem um algoritmo baseado em *Wavelet* (NOVIKOV; PROTASOV; SKOPINA, 2011) e mostram em seus resultados um aumento de contraste das imagens analisadas quando comparado com outras técnicas da área. Al-Najdawi, Biltawi e Tedmori (2015) combinam vários métodos de pré-processamento para segmentar a região da mama, conseguindo melhorar a imagem para segmentação e classificação. O desafio das técnicas de pré-processamento é conseguir melhorar a identificação da região de lesão sem aumentar também o contraste de elementos indesejados, como ruído ou falsos positivos.

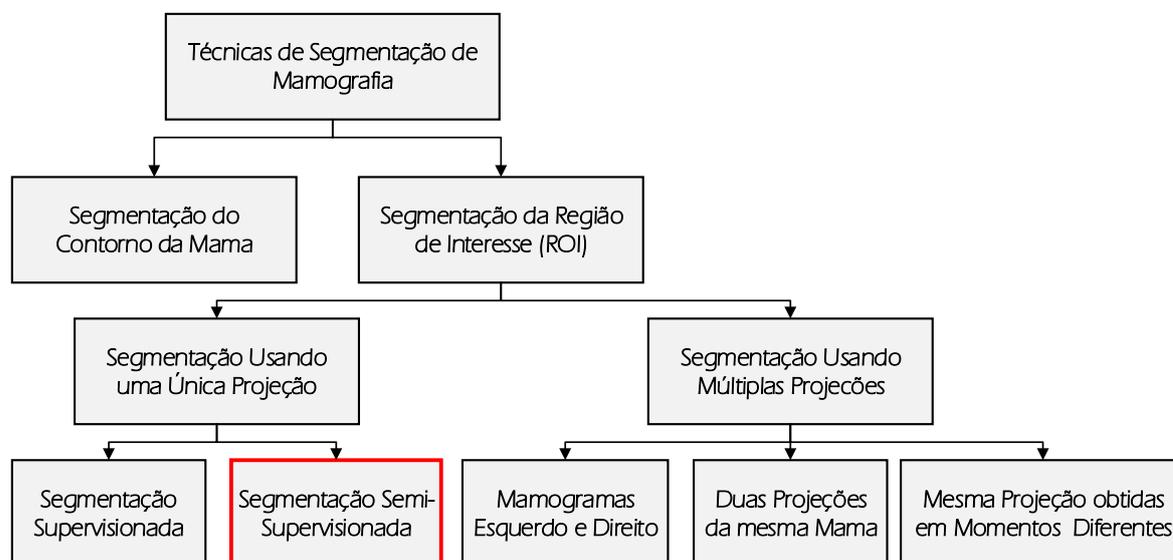
#### 4.1.2 Segmentação

Trabalhos relacionados à segmentação de mamografia digital visam separar uma região ou objeto de interesse de forma automática ou semi-automática, com o objetivo de auxiliar na identificação e diagnóstico de lesões na mama. Alguns autores também usam o termo “massa” para se referir às lesões na mama. Embora nem toda lesão seja um tumor, muitos autores usam esses termos mesmo quando o trabalho envolve apenas segmentação de lesões. Biltawi, Al-Najdawi e Tedmori (2012) classificaram os trabalhos envolvendo segmentação de mamografia de acordo com a Figura 25.

Este trabalho se encontra na subdivisão de segmentação de região de interesse, de forma semi-supervisionada, usando uma única projeção, mostrado com um contorno vermelho na Figura 25.

Uma das etapas iniciais de um processo de segmentação automático envolve a parte de extração da região da mama, separando-a da região de fundo da imagem. Isso é importante, pois no fundo da imagem às vezes estão presentes elementos como rótulos de imagem, ruídos ou objetos indesejados que podem interferir no processo de segmentação. Czaplicka e Włodarczyk (2011) propuseram um método baseado no método de limiar de Otsu e lógica *fuzzy* em limiar local para segmentação da mama, alcançando uma precisão de 95% de acerto. Chen e Zwiggelaar (2010) propõem uma técnica baseada em limiar de histograma, detecção de borda e crescimento de contorno, obtendo precisão de 98,4% na detecção de borda da mama, com remoção do músculo peitoral. Aghdam, Puig e Solanas (2013) falam que métodos de segmentação de mama baseados em limiar e operadores

**Figura 25** – Categorização das técnicas de segmentação de imagens de mamografia.



Fonte: Biltawi, Al-Najdawi e Tedmori (2012).

morfológicos possuem limitações para encontrar valores ótimos de limiar, propondo assim, um método baseado em *local binary patterns* (PIETIKÄINEN et al., 2011), melhorando os resultados obtidos pelos trabalhos comparados.

As técnicas de segmentação de uma região de interesse normalmente têm por objetivo identificar uma região de lesão ou de calcificação na mama. Muitas vezes, elas realizam inicialmente a separação da região da mama para depois realizar a identificação do objeto de interesse. A segmentação da região de interesse, conforme mostra a Figura 25, pode ser realizada através de uma única imagem de uma projeção da mama ou através da combinação de várias projeções. A segmentação através de várias projeções tende a ser mais confiável por ter mais fontes de informação acerca da mesma lesão mamária. No entanto, dado a limitação de bases de dados com diferentes tipos de projeção, torna-se difícil muitas vezes o estudo para esses tipos de casos.

A maioria dos trabalhos de segmentação são voltados para segmentação utilizando uma única projeção, normalmente a Médio Lateral. Isso ocorre porque a maioria das bases públicas de imagens de mamografia digital fornece apenas esse tipo de imagem. Dentre as técnicas de segmentação dessa subárea distinguem-se as técnicas supervisionadas e não supervisionadas.

As técnicas de segmentação supervisionada envolvem algum tipo de interação com o usuário, tal como a seleção de pontos iniciais indicando áreas de lesão e não-lesão. O tipo de interação com o usuário se difere basicamente em dois tipos: a) o usuário realiza uma série de cliques ao redor da borda do objeto de interesse; b) o usuário desenha uma

região simples (ZHU et al., 2014). Trabalhos recentes aplicam técnicas tais como Contornos Ativos, proposto por Chan e Vese (2001), em imagens de mamografia para segmentar regiões de lesão (RAHMATI; ADLER; HAMARNEH, 2012). Técnicas baseadas em grafos também são bastante utilizadas, tal como o trabalho de Wu et al. (2011), que aplica Graph Cuts, proposto por Kolmogorov e Zabini (2004), para segmentação de lesões. Outro método supervisionado baseado em grafos é utilizado por Zheng, Liu e Liu (2013), o qual aplica a técnica *Random Walks* (GRADY, 2006) para a segmentação de lesões.

As técnicas de segmentação não supervisionadas são técnicas automáticas que não envolvem nenhum tipo de interação com o usuário. Nessas técnicas, não é necessário identificar inicialmente a localização de regiões de lesão e de não-lesão, tais como as técnicas supervisionadas. Da mesma forma que as supervisionadas, existem diversas categorias de técnicas não supervisionadas, dentre elas as baseadas em região, contorno, agrupamento, pseudo-cores, grafos, entre outras. Zhang et al. (2009) propõem um método baseado em contorno, obtendo bons resultados de segmentação para a base de dados analisada. Como exemplo de método baseado em região, Rabottino et al. (2011) aplica um método usando Crescimento de Região para realizar segmentação e classificação de lesões.

Alguns trabalhos, como o de Gao et al. (2010), que usa uma abordagem baseada em análise de componentes morfológicos, conseguem obter taxas altas de acerto quanto a localização do lesões. No trabalho de Gao et al. (2010) é obtida uma precisão de 95,3%, para 150 regiões de interesse analisadas. Liu et al. (2012), utilizando crescimento de regiões obtém uma precisão de 97,2% das regiões segmentadas em áreas de lesão. No entanto, esse trabalho depende de muitos parâmetros pré-definidos para obter um bom desempenho. Han et al. (2012) consegue obter até 98,82% quando modela as lesões matematicamente e aplica Fuzzy C-Means. No entanto, essa abordagem tem dificuldade para lidar com lesões do tipo espiculado.

Apesar de trabalhos recentes conseguirem obter boa precisão na identificação da localização de lesões (LIU et al., 2011)(MOHAMED; BEHIELS; DEWAELE, 2009), poucas pesquisas têm sido feitas para verificar a qualidade da segmentação. Trabalhos recentes estão divididos em segmentação baseado em bordas, segmentação baseada em região e limiar adaptativo (RAMAN et al., 2011).

Em métodos de segmentação baseados em borda é difícil determinar o contorno da lesão, principalmente em lesões com bordas não definidas. Métodos de segmentação baseados em região são mais adequados para a detecção de lesões, uma vez que regiões de lesão normalmente são mais claras do que o tecido da vizinhança, possuindo uma densidade quase uniforme e um contorno difuso (RAMAN et al., 2011).

Trabalhos recentes para segmentação de lesão têm aplicado com sucesso técnicas baseadas em região. Lewis e Dong (2012) usa a técnica *Watershed*, proposto por Bleau e Leon (2000), para segmentar automaticamente regiões candidatas de lesão, obtendo taxa

de detecção de lesão de 90%. No entanto, a métrica de análise usada é baseada apenas na localização da lesão e não na qualidade da segmentação. Eltoukhy e Faye (2013) usam uma técnica baseada em limiar adaptativo, alcançando 100% de sensibilidade, com uma média de 1,86 falso positivos, quando aplicado a 188 imagens. Contudo, o valor de sensibilidade varia dependendo da taxa de falso positivo, e cada trabalho usa uma taxa diferente.

Devido à pouca uniformidade presente em lesões presentes em imagens de mamografia digital, conforme descrito por Hong e Sohn (2010), regiões baseadas em sementes, nas quais o usuário rotula sementes iniciais, apresentam uma melhor qualidade na segmentação final. Cordeiro et al. (2012) aplica uma técnica supervisionada baseada em sementes, obtendo resultados de segmentação próximos à imagem ouro fornecida. Zheng, Liu e Liu (2013) utiliza uma segmentação baseada em *Random-Walk*, o qual também usa sementes fornecidas pelo usuário para obter uma boa segmentação. No entanto, no trabalho de Zen não é fornecida uma análise quantitativa dos resultados. Apesar de técnicas baseadas em sementes apresentarem bom desempenho para segmentação de lesões, elas requerem um alto nível de conhecimento sobre o problema para a seleção correta de sementes.

Técnicas não supervisionadas e semi-supervisionadas tentam reduzir o conhecimento necessário sobre a região de lesão. Rahmati, Adler e Hamarneh (2012) usa Contornos Ativos para segmentar lesões, alcançando 86,85% de precisão usando a métrica de sobreposição entre as imagens segmentadas e a imagem ouro. Chakraborty et al. (2012) aplicam limiar multinível combinado com crescimento de região para realizar segmentação para lesões com contorno bem definidos. No entanto, ambas as técnicas encontram dificuldades na definição de contornos de lesões espiculadas e com bordas não-definidas.

Conforme observado por Raman et al. (2011), os resultados dos trabalhos do estado da arte diferem significativamente, e são muitas vezes baseados em uma opinião visual subjetiva e com um embasamento quantitativo muito pequeno. Além disso, a maioria dos estudos descrevem uma precisão das técnicas baseadas apenas na localização da lesão e não na sua forma ou contorno, os quais são muito importantes para o diagnóstico. Poucos trabalhos tratam da análise da qualidade da segmentação da lesão. Além do mais, a maioria dos trabalhos que analisam a qualidade da segmentação usa métricas simples como sobreposição de *pixels* para avaliar a qualidade da segmentação. Avaliar a qualidade da segmentação de forma mais aprofundada, apesar de não ter sido muito focada nos trabalhos mais recentes, é de fundamental importância para o diagnóstico final do paciente, pois é necessário a identificação exata do contorno da lesão para a avaliação e classificação do câncer.

A Tabela 3 mostra um resumo de algumas das principais técnicas supervisionadas de segmentação de lesão do estado da arte. A primeira coluna mostra o autor do trabalho, a segunda coluna apresenta a técnica em que o trabalho se baseia, a terceira coluna mostra a base de dados usada, enquanto a quarta coluna mostra o número de imagens de

mamografia utilizada da base e a quinta coluna mostra a métrica utilizada. A sexta coluna indica se o método supervisionado apresenta robustez quanto à incerteza da marcação pelo especialista. A sétima coluna mostra os principais resultados e a oitava e última coluna mostram as vantagens e desvantagens de cada trabalho, respectivamente. Uma crítica do trabalho é realizada quanto ao número de imagens selecionadas nos trabalhos do estado da arte. Nos trabalhos relacionados não é informado o critério de seleção das imagens e na maioria dos casos não é utilizada nem metade do total de imagens da base, não sendo claro o método de seleção e também não é informado quais imagens foram utilizadas para posterior comparação. Além disso, a maioria dos trabalhos se baseia na métrica de avaliação baseado na sobreposição de *pixels*, o qual não avalia o resultado da final da segmentação quanto à forma. Sendo a forma da lesão um parâmetro importante para o diagnóstico, é importante a utilização de métricas que avaliem quanto a forma da imagem segmentada.

A partir da Tabela 3 observa-se que os métodos supervisionados utilizados da arte não são robustos quanto à indicação inicial fornecida pelo usuário. Desta forma, uma marcação incorreta pode ocasionar em uma segmentação imprecisa, o que deixa o método muito dependente do conhecimento especialista. A partir disso, identificamos a necessidade de tornar o método de segmentação supervisionado mais robusto, o qual pode ser realizado através de duas etapas: a) redução do esforço inicial do posicionamento de sementes; b) adição de incerteza no modelo supervisionado.

A Tabela 4 mostra o resumo das principais técnicas não supervisionadas do estado da arte, aplicadas à segmentação de lesões em imagens de mamografia digital. A primeira coluna mostra o autor do trabalho, a segunda coluna apresenta a técnica em que o trabalho se baseia, a terceira coluna mostra a base de dados usada, a quarta coluna mostra o número de imagens de mamografia utilizada da base e a quinta coluna mostra a métrica utilizada. A sexta coluna indica se o método utiliza algum tipo de limiar, a sétima coluna indica se o método apresenta robustez quanto à imprecisão na seleção automática de sementes. A oitava coluna mostra os principais resultados e a nona e última coluna mostram as vantagens e desvantagens de cada trabalho, respectivamente. Os trabalhos relacionados observados se baseiam principalmente em dois tipos de abordagem: a) utilização de algum tipo de limiar adaptativo para identificação da região de lesão; b) abordagem híbrida utilizando limiar adaptativo ou agrupamento para geração de sementes, juntamente com uma abordagem baseada em sementes. Um dos problemas encontrados é que abordagens baseadas em limiar quando o histograma da imagem apresenta duas classes bem definidas, o que nem sempre ocorre com imagens de mamografia devido à natureza da região da lesão, que pode apresentar baixo contraste e fronteiras indefinidas. Desta forma, a geração incorreta ou imprecisa de sementes na etapa não supervisionada pode gerar uma segmentação imprecisa, uma vez que os métodos da etapa supervisionada não são robusto quanto ao posicionamento incorreto das sementes. Desta forma, conclui-se que mesmo para métodos

**Tabela 3** – Resumo dos principais trabalhos relacionados na segmentação supervisionada de lesões na mama.

Autor	Técnica	Base de Dados	Num. Img.	Métrica	Robustez	Resultados	Vantagem	Desvantagem
(RAHMATI; ADLER; HAMARNEH, 2012)	Contornos Ativos	DDSM	100	Sobreposição de <i>Pixels</i>	Não	81% de precisão	Visualmente apresenta boa segmentação	Usa métrica pouco robusta. Não compara com outras técnicas.
(WU et al., 2011)	Graph Cuts	DDSM	89	ME ( <i>Misclassification Error</i> )	Não	Valor de ME = 0,2531	Compara com a técnica GVF Snake e apresenta melhores resultados	Métrica de análise não reflete qualidade quanto à forma.
(ZHENG; LIU; LIU, 2013)	Random Walks	Mini-MIAS	15	Localização dentro da área indicada no Mini-MIAS	Não	14 de 15 imagens apresentaram localização correta	Para as imagens analisadas os resultados foram muito bons	O trabalho não faz análise quanto à qualidade da forma da segmentação. Poucas imagens analisadas.
(RABOTTIN et al., 2011)	Crescimento de Região	DDSM	200	Acurácia, Precisão, Sensibilidade	Não	Mostra algumas imagens com precisão de 98%, mas não mostra o resultado médio.	Simples e com boa segmentação para os casos mostrados.	Alto custo computacional e dependente da inicialização.
Zewei et al. (2014)	Line Wire e Fuzzy C-Means	DDSM	68	Taxa de Verdadeiro Positivo (VP), Taxa de Falso Positivo (FP)	Não	TP = 96,64, FP = 1,95%	Alta precisão	Quantidade alta de parâmetros
Rahmati, Adler e Hamarneh (2012)	Contornos Ativos	DDSM	100	Sobreposição de <i>Pixels</i>	Não	86% de precisão	Boa segmentação	Dependente da seleção inicial. Muitos parâmetros.

não supervisionados onde há uma seleção automática de sementes, é necessário adicionar incerteza no modelo baseado em sementes, visto que a geração das sementes é de natureza imprecisa.

### 4.1.3 Classificação

Normalmente, após a realização da segmentação da lesão, é utilizada a aplicação de algum algoritmo para realização da classificação automática da região quanto ao tipo de lesão. Vários trabalhos têm sido realizados nessa área, onde a maioria é baseada na extração de característica da região e em seguida aplica-se um classificador. Como exemplo, Jiji e Marsilin (2015) propõe um método de detecção da lesão através da recuperação de mamogramas de casos passados, atingindo taxa de acerto de 87%. Anitha e Peter (2012) aplicaram a técnica Wavelet juntamente com a matriz de co-ocorrência na região de interesse para a extração de características. Para classificar a região utilizaram a técnica SVM, descrita por Steinwart e Christmann (2008), obtendo uma taxa de acerto de 95%.

## 4.2 ALGORITMOS SUPERVISIONADOS DE SEGMENTAÇÃO DE LESÕES UTILIZADOS NO ESTADO DA ARTE

Nesta seção, serão apresentados alguns dos algoritmos de segmentação supervisionados utilizados no estado da arte para segmentação de lesões. As técnicas descritas nesta seção foram implementadas neste trabalho.

### 4.2.1 Contornos Ativos

O algoritmo de Contornos Ativos, proposto por Kass, Witkin e Terzopoulos (1988), é uma técnica usada extensivamente para identificar bordas de regiões de interesse em imagens. Em resumo, essa técnica tenta minimizar a energia associada com o contorno de uma região como uma soma de energias internas e externas. Essa técnica consegue ter bom desempenho mesmo em regiões com contornos com pouco contraste e presença de ruído. A técnica precisa de uma interação inicial com o usuário para selecionar um contorno inicial em torno ou dentro de um objeto de interesse. Essa curva inicial se deforma a cada iteração, tentando minimizar a energia associada ao contorno, até atingir a convergência, apresentando a identificação final do contorno. Devido à eficiência da técnica, alguns pesquisadores na área têm aplicado Contornos Ativos para segmentação de lesões (RAHMATI; ADLER; HAMARNEH, 2012; TUNALI; KILIC, 2013), com algumas adaptações dependendo do trabalho.

De acordo com o trabalho original, uma *snake* é uma curva que se move pela imagem buscando minimizar a energia funcional, que é uma combinação de energia interna e externa. A correspondência do modelo com o contorno só é alcançada pela procura de um vetor que minimize a soma dessas energias. A conformidade do contorno só é

**Tabela 4** – Resumo dos principais trabalhos relacionados na segmentação não supervisionada de lesões na mama.

Autor	Técnica	Base de Dados	Num. Img.	Métrica	Limiar	Robustez	Resultados	Vantagem	Desvantagem
(PEREIRA; RAMOS; NASCIMENTO, 2014)	Wavelet e Algoritmo Genético	DDSM	160	Sobreposição de <i>Pixels</i>	Sim	Não	79,2%	Segmentação de imagens CC e MLO	Métrica de Análise não reflete qualidade quanto à forma.
(HONG; SOHN, 2010)	Limiar Multi-nível e topologia topográfica	USF	400	Sobreposição de <i>Pixels</i>	Sim	Não	90% com 2,3 falsos positivos por imagem	Algoritmo simples	Alto número de falso positivos por imagem
(LEWIS; DONG, 2012)	Watershed e análise morfológica	Mini-MIAS	161	Localização dentro da área indicada no Mini-MIAS	Sim	Não	90% de acerto	Identificação da localização da lesão de forma automática	Não trata casos de falso positivo.
(JAI-ANDALOUSSI et al., 2013)	BEMD	Mini-MIAS	111	Sobreposição de <i>Pixels</i>	Sim	Não	83,96%	Algoritmo Simples	Métrica de Análise não reflete qualidade quanto à forma.
(BERBER et al., 2013)	BMCS	DEMS	260	Sobreposição de <i>Pixels</i>	Sim	Não	83,15%	Alta acurácia comparada com técnicas analisadas	Alto custo computacional
(SHARMA; KHANNA, 2013)	LBI	IRMA	818	Métrica baseada em verdadeiro e falso positivo	Sim	Não	93%	Validação para grande número de imagens	Parâmetros não definidos no artigo
(GAO et al., 2010)	Análise de Componentes Morfológicos	DDSM	150	Localização da região segmentada	Sim	Não	95,3% de acerto em média	Alta precisão da localização	Analisa apenas o acerto da localização da região segmentada.
(HAN et al., 2012)	Modelagem Matemática e Fuzzy C-Means	Mini-MIAS	100	Localização da região segmentada	Não	Não	98,82%	Alta precisão da localização	Depende do formato da lesão descrito na modelagem matemática
(LIU et al., 2012)	Template Matching e Crescimento de Região	DDSM	70	Localização da região segmentada	Sim	Não	97,2%	Alta precisão da localização	Depende de parâmetros específicos, como intervalo de limiar pré-definido.

alcançada quando a soma for igual a zero. É possível definir a energia da *snake* através da Equação 4.1.

$$E_{\text{snake}} = E_{\text{int}} + E_{\text{ext}}. \quad (4.1)$$

Conforme a Equação 4.1, a energia da *snake* é definida pelo somatório da energia interna e energia externa, representados respectivamente por  $E_{\text{int}}$  e  $E_{\text{ext}}$ . A energia interna depende do contorno da curva. Quanto mais suave o contorno, menor a energia interna. A energia externa permite uma adaptação sobre o contorno dos objetos. É a energia externa que evita que o *snake* se contraia sobre si mesmo, sem perceber o contorno da imagem. As definições de  $E_{\text{int}}$  e  $E_{\text{ext}}$  são mostradas nas Equações 4.2 e 4.3.

$$E_{\text{int}} = \sum_{p \in P} D_p(L_p), \quad (4.2)$$

$$E_{\text{ext}} = \sum_{\{p,q\}} V_{pq}(L_p, L_q), \quad (4.3)$$

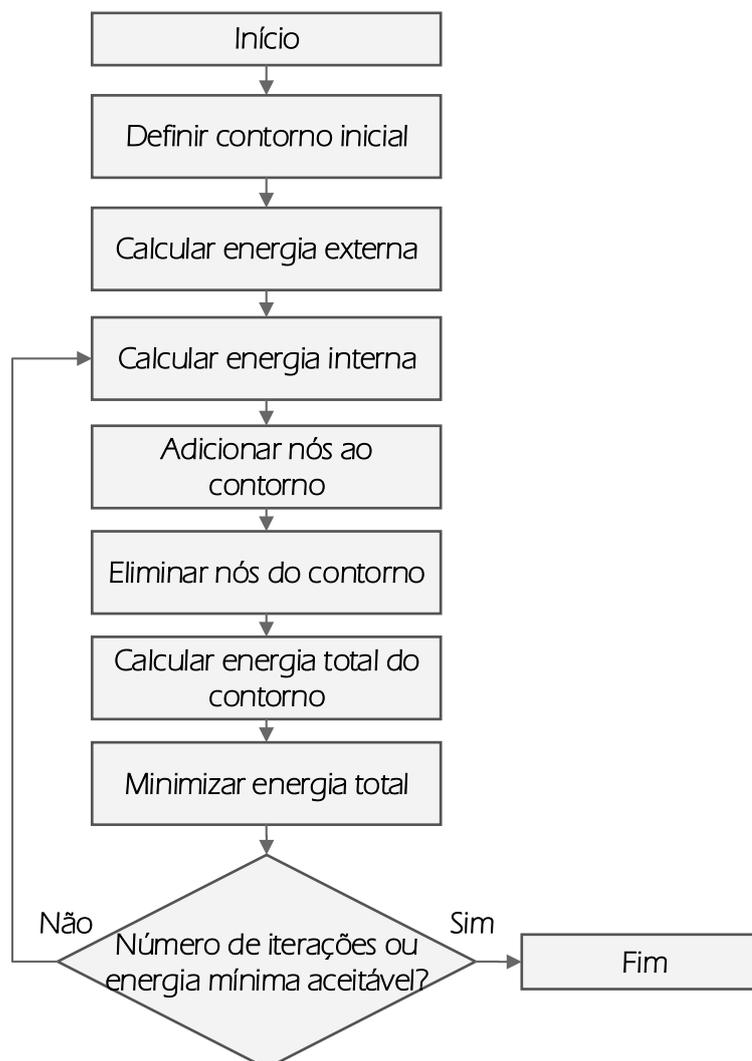
onde  $p$  e  $q$  são *pixels* pertencentes ao conjunto de *pixels*  $P$  da imagem,  $L$  é o rótulo do *pixel*, isto é, se ele é classificado como objeto ou fundo,  $D_p$  é uma função de penalidade e  $V_{pq}$  é o potencial de iteração, que mede o custo de rotular os *pixels* vizinhos. Os valores de  $D_p$  e  $V_{pq}$  são representados pelas equações 4.4 e 4.5.

$$D_p(L_p) = -\ln P(L_p|I_p), \quad (4.4)$$

$$V_{pq}(L_p, L_q) = \begin{cases} \beta_{pq}, & L_p \neq L_q \\ 0, & L_p = L_q \end{cases}, \quad (4.5)$$

onde  $I_p$  é a intensidade do *pixel*  $p$ ,  $P(L_p|I_p)$  é a probabilidade de um *pixel*  $p$  com intensidade  $I_p$  assumir rótulo  $L$ . O valor de  $P(L_p|I_p)$  é estimado baseado no histograma. O coeficiente  $\beta_{pq} \geq 0$  penaliza discontinuidades entre *pixels* vizinhos. Normalmente  $\beta_{pq}$  é alto para *pixels* com intensidades similares e próximo a zero quando as intensidades são diferentes. No mecanismo adotado por Chan e Vese (2001), os *pixels* são representados através de grafos, onde têm-se como objetivo encontrar o corte com custo mínimo. O fluxograma da técnica de Contornos Ativos é apresentado na Figura 26.

Inicialmente é definido um contorno inicial, que o algoritmo irá se basear para tentar ajustar o contorno ao objeto de interesse. A localização do contorno inicial tem um impacto importante no resultado final da segmentação. Em seguida, são calculadas as energias internas e externas, e a curvatura é ajustada de forma a minimizar a energia total encontrada. Para cada nó do contorno é feita a adição e remoção de nós em sua região de

**Figura 26** – Fluxograma da Técnica Contornos Ativos.

Fonte: do autor.

vizinhança, de forma a minimizar a energia total. Quando o algoritmo obtiver um valor de energia mínima aceitável ou atingir o número de interações desejável então o processo é finalizado.

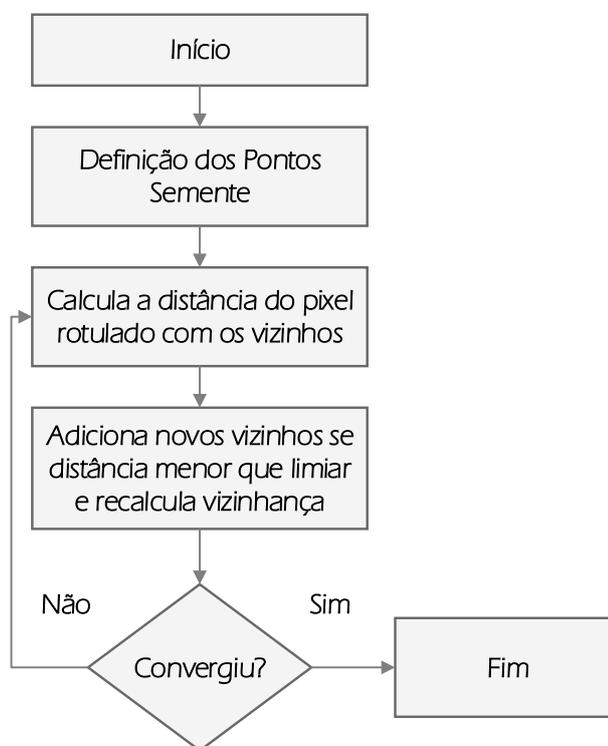
#### 4.2.2 Crescimento de Região

Crescimento de Região (GONZALEZ; WOODS; EDDINS, 2009) é uma técnica clássica de processamento de imagem, que tem sido aplicada para segmentar imagens em diversas áreas, incluindo mamografia digital (CHAKRABORTY et al., 2012). O Crescimento de Região é uma técnica de segmentação simples, onde o usuário inicialmente seleciona pontos semente e o algoritmo adiciona *pixels* vizinhos que são similares a cada semente. Quando a região termina de crescer o algoritmo converge e a segmentação final é obtida. Essa é uma técnica que também depende da escolha do ponto semente para

realizar uma boa segmentação.

O fluxograma da técnica de Crescimento de Região é mostrado na Figura 27. Inicialmente, são definidos pontos semente onde se deseja fazer um agrupamento dos *pixels* da vizinhança. Em seguida, para cada ponto semente, que possui um rótulo inicial, calcula-se a distância em relação aos *pixels* vizinhos. Essa distância pode ser uma métrica baseada na diferença de intensidade dos *pixels*. Se essa distância for menor que um determinado valor, o *pixel* vizinho passa a assumir o mesmo rótulo do *pixel* inicial. Ao final dessa etapa a vizinhança de *pixels* similares aumenta e o processo é repetido. Quando a região parar de aumentar e convergir então o processo é finalizado.

**Figura 27** – Fluxograma da técnica Crescimento de Região.



Fonte: do autor.

### 4.2.3 Graph Cut

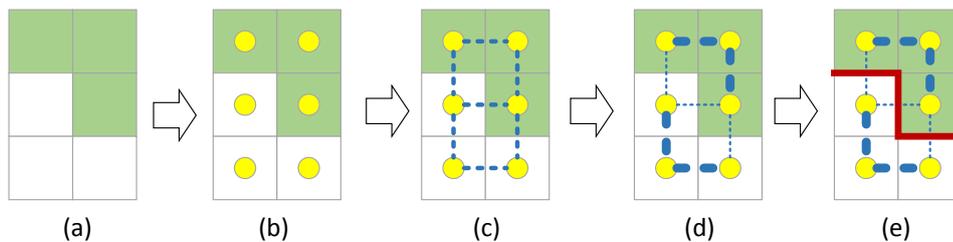
Graph Cut (GRADY, 2006) é um método baseado em grafos e é bastante utilizado em segmentação de imagens. Na segmentação de lesões em mamogramas, a técnica foi aplicada por Wu et al. (2011), que obteve bons resultados quando combinado com a técnica Watershed.

O Graph Cut requer a seleção inicial de sementes contendo *pixels* de fundo e do objeto. Nessa técnica, a imagem é mapeada em um grafo cujo objetivo é estabelecer um corte mínimo para a separação dos nós do grafo. O corte em um grafo é o particionamento

dos nós em grupos disjuntos. Cada corte tem um custo associado, de forma que o Graph Cut tenta resolver o problema do corte mínimo, que consiste em encontrar um corte com o menor custo possível.

A Figura 28 mostra o processo de corte do grafo realizado pelo Graph Cut. Inicialmente é mostrada uma imagem 2x3 na Figura 28 (a), onde cada *pixel* é mapeado como sendo um nó do grafo, como mostrado na Figura 28 (b). Em seguida, cada nó é ligado por arestas, como mostra a Figura 28 (c). Para cada aresta é atribuído um custo, que é baseado no grau de similaridade entre os *pixels* conectados. Quanto maior a similaridade entre vizinhos, maior o custo. Esse grau de similaridade é baseado na intensidades dos *pixels*. A Figura 28 (d) ilustra as arestas com maior peso como tendo uma aresta mais espessa, enquanto as com menor peso têm aresta mais fina. Por fim, o algoritmo faz um corte de custo mínimo no grafo, como mostra a Figura 28 (e).

**Figura 28** – Corte de grafo de custo mínimo da técnica Graph Cut.



Fonte: do autor.

#### 4.2.4 Random Walks

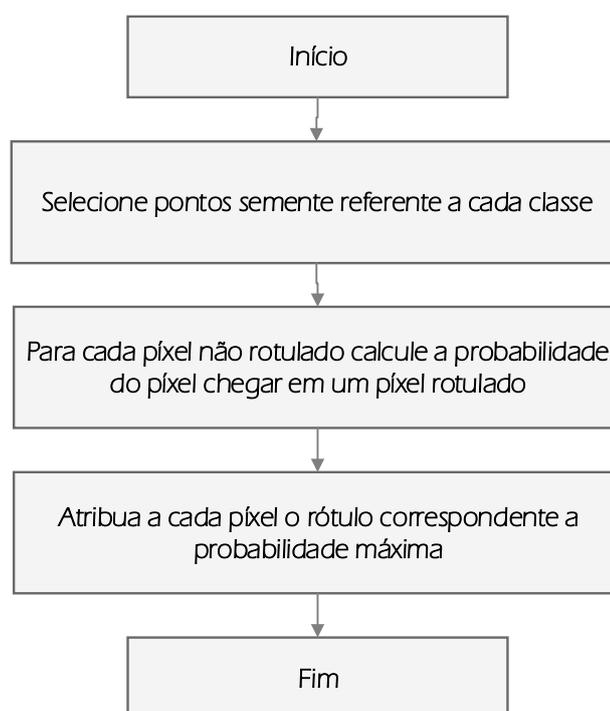
*Random Walks*, utilizado por Wang e Landau (2001), é outro método baseado em grafos onde cada *pixel* é representado como um nó e está conectado a *pixels* vizinhos por arestas. O grafo começa com a definição das sementes de fundo e do objeto de interesse, ambas definidas pelo usuário. Essa técnica tem sido também usada para segmentar lesões em mamogramas, encontrando regiões de tumor com precisão (ZHENG; LIU; LIU, 2013). A implementação do Random Walks usada nesse trabalho é a mesma utilizada no trabalho de Andrews, Hamarneh e Saad (2010).

A ideia do algoritmo é que para determinarmos a que classe (objeto ou fundo) pertence um *pixel*  $u$ , consideramos passeios aleatórios (*random walks*, em inglês) que iniciam em  $u$  e terminam assim que chegam em um *pixel* rotulado. Calcula-se então a probabilidade de cada rótulo ser o primeiro a ser atingido, a partir de um passeio aleatório iniciado em  $u$ . O rótulo que possui maior probabilidade de ser atingido é atribuído a  $u$ . A probabilidade de um passeio aleatório do nó  $u$  até o nó  $j$  é dada pela Equação 4.6:

$$p_{uj} = \frac{w_{uj}}{\sum_{k \in N(u)} w_{uk}}, \quad (4.6)$$

onde  $p_{uj}$  é a probabilidade de um *pixel* sair do ponto  $u$  e chegar no ponto  $j$ ,  $w_{uj}$  é o peso associado entre  $u$  e  $j$ , e  $N(u)$  é a vizinhança do ponto  $u$ . Como os pesos representam as diferenças entre os *pixels*, os passeios têm maior probabilidade de percorrerem regiões mais uniformes, evitando bordas.

**Figura 29** – Fluxograma do algoritmo Random Walks.

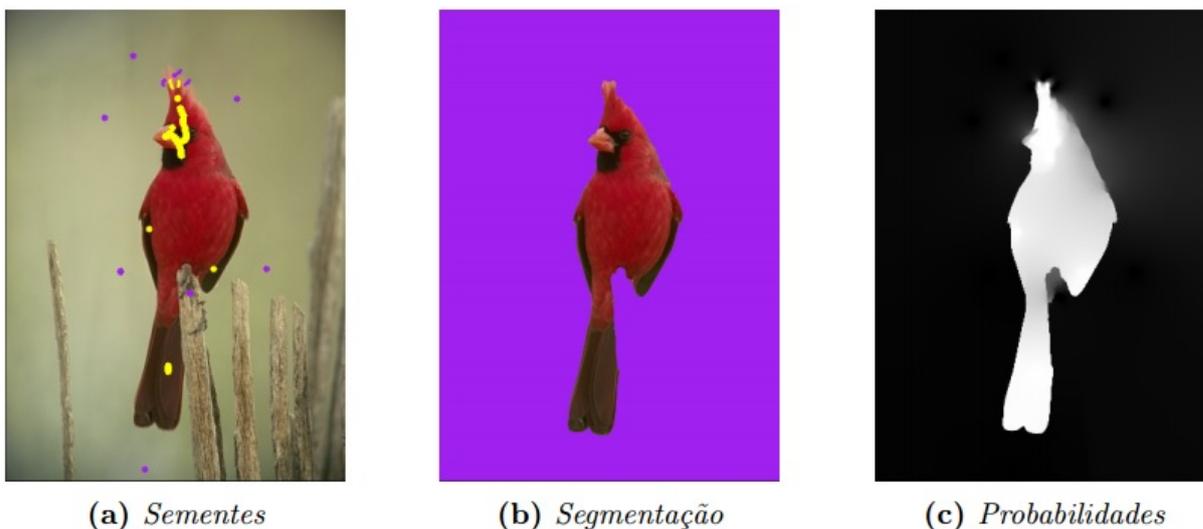


Fonte: do autor.

O algoritmo do Random Walks é ilustrado no fluxograma da Figura 29. Conforme mostrado na Figura 29, inicialmente são definidas as sementes referentes a cada classe a ser segmentada. No caso de mamografia são definidas selecionando-se regiões iniciais de lesão e não-lesão. Em seguida, para cada *pixel* é calculada a probabilidade de ele chegar em um *pixel* rotulado. O *pixel* receberá o rótulo com a maior probabilidade calculada. O mesmo processo é repetido para todos os *pixels* não rotulados da imagem.

A Figura 30, retirada do trabalho de Ascaneo (2012), ilustra o processo envolvido no algoritmo Random Walks. A Figura 30 (a) mostra a seleção das sementes, realizada pelo usuário, onde os pontos em roxo representa a classe de fundo e os pontos amarelos a classe do objeto a ser segmentado. A Figura 30 (b) mostra a segmentação final obtida e na Figura 30 (c) mostra a probabilidade dos *pixels* da imagem, onde *pixels* de intensidade similar tendem a ter probabilidade próxima de pertencer a uma determinada classe.

**Figura 30** – Segmentação de um pássaro, com rótulos de objeto e fundo, utilizando Random Walks.



Fonte: Ascaneo (2012).

### 4.3 ALGORITMOS NÃO SUPERVISIONADOS DE SEGMENTAÇÃO DE LESÕES UTILIZADOS NO ESTADO DA ARTE

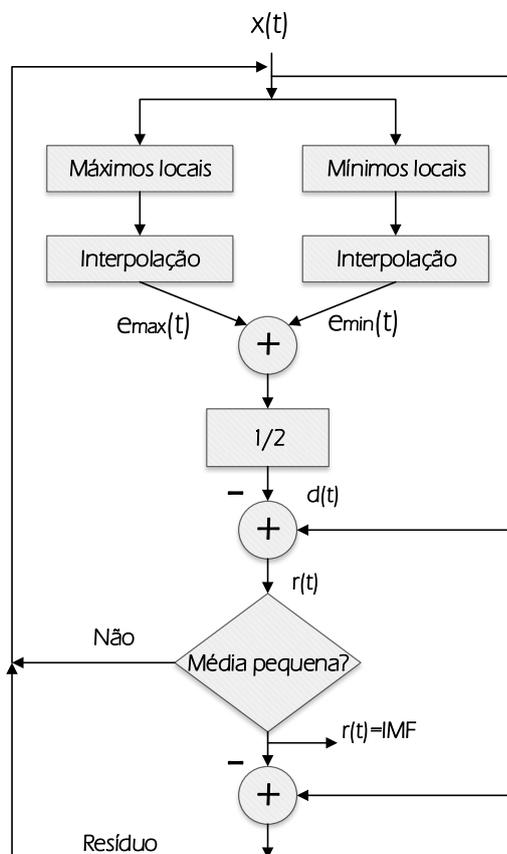
Nesta seção serão apresentados alguns dos algoritmos de segmentação não supervisionados utilizados no estado da arte para segmentação de lesões. As técnicas descritas nesta seção foram implementadas neste trabalho.

#### 4.3.1 BEMD

O algoritmo proposto por Jai-Andaloussi et al. (2013), aplica o método bidimensional de decomposição de modos empíricos (*Bidimensional Empirical Mode Decomposition*, BEMD) para realizar a segmentação de imagens de mamografia digital. Métodos de decomposição separam um sinal em componentes simples e as processa de forma independente. Essa abordagem normalmente é usada para dividir um problema complexo em problemas de resolução mais simples. O método BEMD é usado para decompor a imagem em um conjunto de funções chamadas modos intrínsecos (*Bidimensional Intrinsic Mode Functions*, BIMF) e um resíduo. O método de decomposição de modos empírico (*Empirical Mode Decomposition*, EMD) é um método de decomposição adaptativa que divide um sinal em um conjunto de sinais chamados IMF e um resíduo (HUANG et al., 1998). Os sinais IMF são obtidos através de um algoritmo chamado de processo de peneira (*sifting algorithm*, em inglês), mostrado na Figura 31.

Conforme descrito no algoritmo da Figura 31, dado um sinal  $x(t)$ , é feita a identificação de todos os máximos locais e mínimos locais de  $x(t)$ . Em seguida, interpolam-se os extremos obtidos no ponto anterior, obtendo os envelopes superior e inferior de  $x(t)$ .

Figura 31 – Algoritmo EMD.

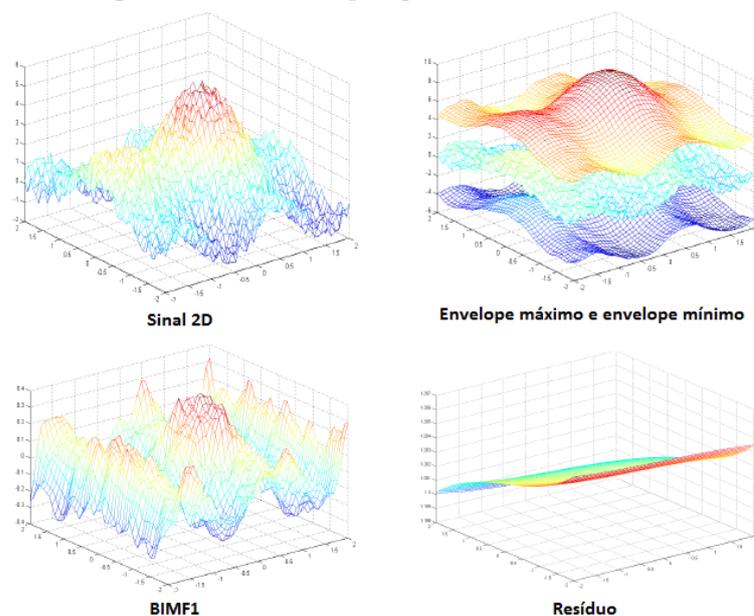


Fonte: do autor.

Depois, é calculada a média dos envelopes, representada por  $d(t)$ , a qual dá-se o nome de *detalhe*. Ao extrair o *detalhe* do sinal inicial obtém-se o resíduo, representado por  $r(x)$ . O processo é repetido enquanto o sinal permanecer praticamente inalterado em relação à iteração anterior. O sinal obtido, após o número de iterações necessárias é uma IMF. O processo se repete até a IMF ou o resíduo atingirem valores pré-definidos.

De acordo com Nunes et al. (2003), o processo de peneira do BEMD segue o mesmo processo do algoritmo EMD, porém aplicado a duas dimensões. Na Figura 33 é mostrado um exemplo de decomposição de sinal para sinal 2D, usando BEMD.

Na segmentação de imagens de mamografia, o BEMD decompõe a imagem em várias BMIFs, que fornecem informação de frequência da imagem original. O primeiro BIMF representa a variação da imagem em diferentes escalas de espaço, o qual contém os componentes de frequência mais altos. Uma vez que as bordas são basicamente descontinuidades na densidade da imagem devido a mudanças na estrutura da imagem, eles correspondem às frequências espaciais locais mais altas (GONZALEZ; WOODS; EDDINS,

**Figura 32** – Decomposição BEMD de sinal 2D.

Fonte: Jai-Andaloussi et al. (2013).

2009). O primeiro BIMF é binarizado de acordo com a Equação 4.7.

$$T = \max F_i = \max F_1 \times r, \quad (4.7)$$

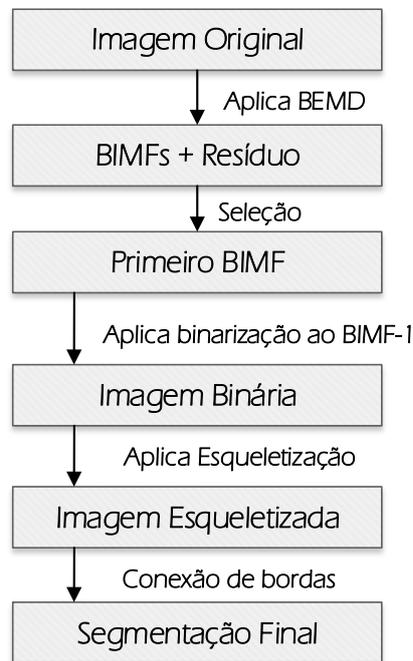
onde  $\max F_1$  representa o valor máximo dos *pixels* no primeiro BIMF e  $r$  é o resíduo. Após o processo de binarização é aplicado o operador de esqueletização para remover os *pixels* ao redor da borda da lesão. Por fim é aplicado um algoritmo para conectar os *pixels* resultantes. O fluxograma completo do BEMD aplicado a imagem de mamografia é mostrado na Figura 33.

#### 4.3.2 BMCS

O algoritmo BMCS (BERBER et al., 2013) é uma abordagem de segmentação de lesões a partir de uma região de interesse e é um tipo de técnica baseada em crescimento de região. O BMCS contém 3 etapas: (1) Pré-processamento, (2) estimativa do tamanho da lesão e (3) segmentação. Na etapa de pré-processamento são aplicados vários filtros para aumentar o contraste entre a região da lesão e o tecido mamário. Nessa etapa são aplicados filtro de média, de mediana e o filtro Laplaciano para enfatizar a informação das bordas da lesão.

Na etapa de estimativa da lesão é aplicado algoritmo de segmentação de OTSU para dividir a ROI em grupos chamados de segmento pequeno e segmento grande. Desta forma, é assumido que o tamanho da lesão deve estar entre a o tamanho do menor e do

**Figura 33** – Processo de segmentação de lesão em imagem de mamografia baseada em BEMD.



Fonte: do autor.

maior segmento. O valor do limiar encontrado pelo método de OTSU também é utilizado na terceira etapa.

O método BMCS requer um conjunto de *pixels* sementes pré-definidas em uma imagem e a expansão desses pontos é feita adicionando os *pixels* vizinhos enquanto for satisfeita a condição da Equação 4.8

$$|\mu - I_{x',y'}| < \Theta, \quad (4.8)$$

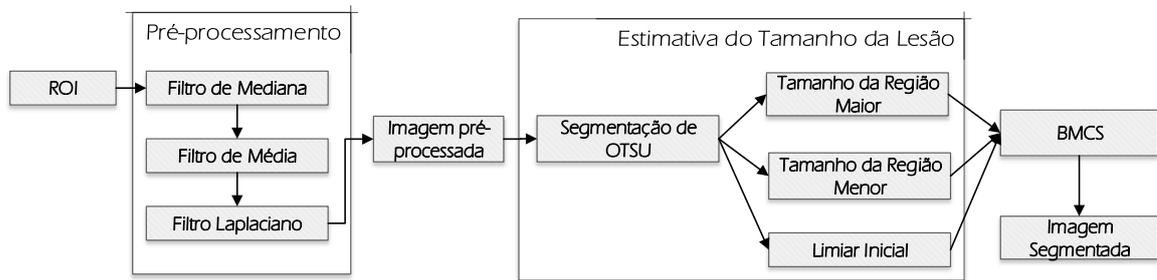
onde  $\mu$  é a média de intensidade da região segmentada,  $I_{x',y'}$  e a intensidade do ponto  $(x', y')$  que é o vizinho da região segmentada e  $\Theta$  o limiar. O valor de  $\mu$  é recalculado cada vez que um novo *pixel* é adicionado na região. O BMCS usa um limiar adaptativo, que regula o limiar baseado no tamanho da região segmentada e da região estimada. O fluxograma mostrando as etapas do algoritmo é mostrado na Figura 34.

O algoritmo do BMCS é mostrado no Pseudocódigo 1.

#### 4.3.3 MCW

O algoritmo MCW, utilizado por Lewis e Dong (2012), usa um método de segmentação de lesões baseado na técnica Watershed (LI et al., 2010) e em marcadores de

**Figura 34** – Processo de segmentação de lesão em imagem de mamografia do algoritmo BMCS.



Fonte: do autor.

---

### Pseudocódigo 1 BMCS

---

```

1: teste : ROI
2: function BMCS(ROI)
3:   Width, Height ← Tamanho da ROI
4:   H ← Histograma da ROI
5:   Elimina da ROI os pixels com 5% maiores e menores valores de H
6:   Aplica filtro de mediana para a ROI com 5% do MAX(Width, Height)
7:   Aplica filtro de suavidade para a ROI com 5% do MAX(Width, Height)
8:   Aplica filtro Laplaciano para a ROI com 5% do MAX(Width, Height)
9:   T ← ponto de divisão de OTSU da ROI
10:  MinSize ← número de pixels com intensidade acima de T
11:  MaxSize ← número de pixels com intensidade abaixo de T
12:  if MaxSize < MinSize then
13:    Troca valores de MaxSize e MinSize
14:  end if
15:  MassRegion ← {}
16:  NeighbourPixels ← {}
17:  CurrentPixel ← Pixel com valor máximo
18:  while Intensidade(CurrentPixel) > T e Tamanho(MassRegion) > MaxSize do
19:    NeighbourPixels ← NeighbourPixels ∪ Vizinhança de CurrentPixel
20:    MassRegion ← MassRegion ∪ CurrentPixel
21:    CurrentPixel ← Maior valor da vizinhança
22:    if Intensidade(CurrentPixel) ≤ T then
23:      if Tamanho(MassRegion) < MinSize then
24:        T ← T - 1
25:      end if
26:    end if
27:  end while
28:  return MassRegion
29: end function

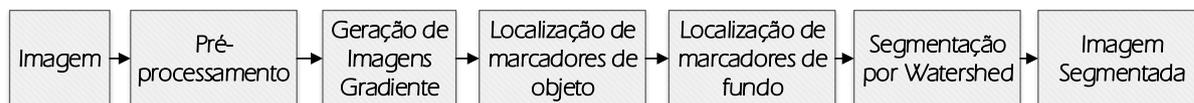
```

---

objeto e fundo para ajudar o modelo. Conforme Lewis e Dong (2012), a aplicação direta da técnica *Watershed* não apresenta resultados confiáveis. Dessa forma, o modelo MCW

restringe a segmentação do *Watershed* utilizando marcadores selecionados via operações morfológicas. O processo de segmentação utilizado no MCW é mostrado na Figura 35.

**Figura 35** – Processo de segmentação de lesões em imagem de mamografia do algoritmo MCW.



Fonte: do autor.

Inicialmente a imagem é submetida a um pré-processamento para melhorar a qualidade da imagem e remover ruídos. O segundo passo é a geração da imagem gradiente para a segmentação. Para isso são utilizados dois filtros de *Sobel* (GONZALEZ; WOODS; EDDINS, 2009), uma no eixo horizontal e outra no eixo vertical. Esse processo gera duas imagens de borda, que são usadas para calcular a imagem gradiente. Após essa etapa são computados os marcadores de objeto e de fundo. Para selecionar os marcadores de objeto são localizadas as regiões de máximo local, uma vez que regiões de lesão normalmente tem maior intensidade do que a região de vizinhança. Antes do processo de localização dos marcadores são aplicados operadores de abertura por reconstrução e fechamento por reconstrução. Esse processo é realizado para remover os *pixels* de maior intensidade das bordas. O processo de localização dos marcadores de fundo é obtido usando um método de limiar adaptativo. Em seguida, os marcadores obtidos são mapeados na imagem gradiente, a qual é modificada que os mínimos locais ocorram apenas onde os marcadores estão localizados. Por fim, é realizada a segmentação do *watershed*, limitada pelos marcadores, na imagem gradiente, obtendo a imagem segmentada.

#### 4.3.4 WAGA

Pereira, Ramos e Nascimento (2014) propõe uma técnica baseada em *Wavelets* (NEULAND, 2012) e Algoritmos Genéticos (CHAMBERS, 2010). Como no artigo original não é dado um nome para a técnica, ara fins de referência, será adotada a sigla WAGA (*WAvelets and Genetics Algorithms*) para se referir a técnica proposta por Pereira, Ramos e Nascimento (2014).

O WAGA usa um algoritmo de segmentação proposto por Hammouche, Diaf e Siarry (2008), que combina a teoria de *wavelets* com algoritmos genéticos (*genetics algorithms*, GA), para determinar o número de limiares para cada imagem de mamografia, assim como o nível de limiar adequado.

Inicialmente é computado o histograma da imagem para obter a representação da imagem em tons de cinza. Para acelerar o processo de convergência do GA, o histograma é reduzido usando transformadas *wavelet* (GONZALEZ; WOODS; EDDINS, 2009). O

histograma é decomposto em sinais aproximado e detalho o sinal aproximado é uma versão reduzida do histograma, mas que contém as características do histograma original. Após a redução do histograma, o GA é aplicado para determinar o número de limiares e seus respectivos valores. O propósito do GA é classificar a imagem de mamografia em  $k$  classes com um conjunto de limiares  $T = t_0, t_1, \dots, t_k$ . A função de aptidão do GA, usado para classificar os níveis de cinza como uma classe  $k$ , é dada pela Equação 4.9.

$$\text{Fit}(k) = \rho \sqrt{\text{Dis}(k)} + (\log_2(k))^2, \quad (4.9)$$

onde  $\text{Fit}(k)$  é a função de aptidão da classe  $k$ ,  $\text{Dis}(k)$  é a medida de discrepância entre a imagem original e a imagem binarizada e  $\rho$  é uma constante. O GA determina o número de classificação ótima  $k^*$ , definido pela Equação 4.11

$$\text{Fit}(k^*) = \min_{k \in L_j^+} \text{Fit}(k), \quad (4.10)$$

onde  $L_j^+ = (1, 2, \dots, L_j)$ . O termo de discrepância é definido pela Equação 4.11.

$$\text{Dis}(k) = \sigma_T^2 - \sigma_B^k, \quad (4.11)$$

onde  $\sigma_T^2$  e  $\sigma_B^k$  representam a variância total da classe e a variância entre classes, respectivamente.

Uma vez que os valores de limiar são obtidos pelo GA a partir do histograma reduzido, esses valores são expandidos para o espaço original. Para isso, cada limiar  $t_i$  é multiplicado por um fator  $2^j$ . Após determinar o número de limiares e seus valores, a segmentação é finalizada aplicando a Equação 4.12

$$B(x, y) = i \text{ se } t_{i-1} \leq f(x, y) \leq t_i, \quad i = 1, 2, \dots, k, \quad (4.12)$$

onde  $f(x, y)$  é a imagem original e  $B(x, y)$  é a imagem segmentada.

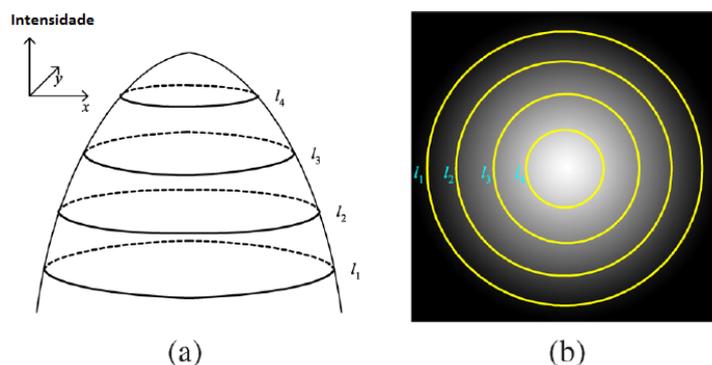
Após a imagem segmentada é aplicada uma etapa de pós processamento para eliminar os falso-positivos.

#### 4.3.5 Modelo Topográfico

A abordagem proposta por Hong e Sohn (2010) utiliza um modelo de limiares multiníveis, que separa a imagem em vários níveis de contornos de mesma intensidade, chamados de isocontornos. A Figura 36 mostra a superfície definida pelos níveis de limiareas, na Figura 36(a), e os isocontornos sobrepostos, na Figura 36(b).

Uma das principais características dos mapas de isocontorno é o aninhamento. Isocontornos dentro de um objeto saliente formam um padrão de estrutura densa, com

**Figura 36** – Ilustração do modelo topográfico. (a) Modelo de superfície e níveis de cinza. (b) Isocontornos sobrepostos na imagem.

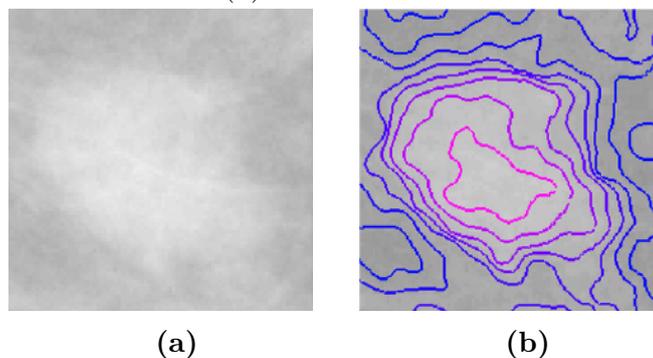


Fonte: Hong e Sohn (2010).

isocontornos sobrepostos. Além disso, geralmente os isocontornos dentro de um objeto possuem contorno similar ao contorno do objeto.

O benefício da aplicação de isocontornos em imagens de mamografia é que as lesões normalmente são objetos sobressalientes na imagem e regiões de lesão geralmente contém isocontornos alinhados. A Figura 37 mostra um exemplo da localização dos isocontornos em uma região de lesão.

**Figura 37** – Ilustração da sobreposição de isocontornos. (a) Exemplo de Lesão. (b) Isocontornos no local da lesão.



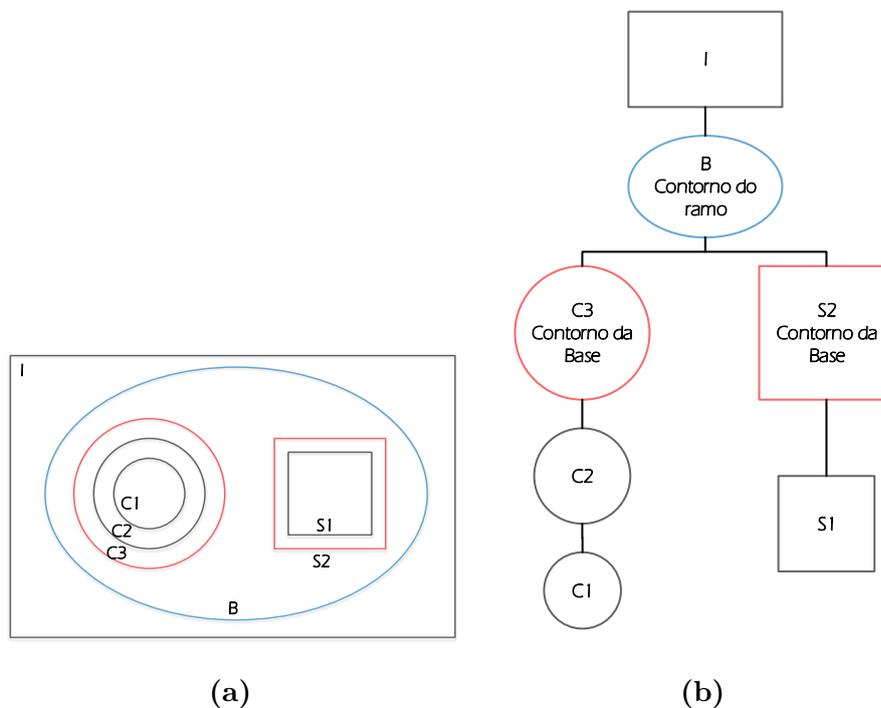
Fonte: Hong e Sohn (2010).

A abordagem topográfica utiliza uma representação de árvore de inclusão, a qual estrutura o aninhamento das regiões de isocontorno. A Figura 39 mostra essa representação.

A árvore de inclusão, representada na Figura 39 é composta por vários nós, correspondente aos níveis de isocontorno definidos pelos limiares. A raiz da árvore é a região da imagem inicial e os nós vão sendo adicionados à medida que uma região de isocontorno esteja contida em outra. Caso uma região contenha duas regiões de isocontorno, ela é chamada de ramo, conforme representado no ramo *B* da Figura 39.

O método topográfico consiste em mapear a imagem de mamografia em uma árvore

**Figura 39** – Ilustração da árvore de inclusão. (a) Mapa de isocontornos contendo contorno de ramo e contorno de base. (b) Árvore de inclusão correspondente.



Fonte: Hong e Sohn (2010).

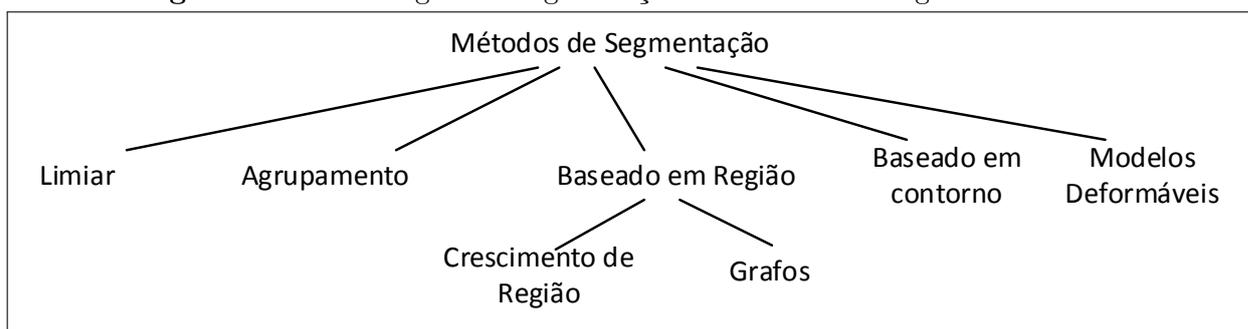
de inclusão. Uma vez mapeado é feita a segmentação a partir da base de isocontorno sem ramificações. Também é definido um aninhamento mínimo para realização da segmentação. Os níveis de isocontorno também podem ser ajustados para ter uma segmentação mais refinada, o que envolve a adição de novos limiares.

#### 4.4 ANÁLISE DE ALGORITMOS DE SEGMENTAÇÃO DE IMAGENS MÉDICAS

Na seção 4.1 foram apresentados os principais métodos de segmentação de lesões utilizados no estado da arte. Nessa seção é feita uma análise das principais abordagens de segmentação em imagens médicas, a fim de escolher a principal abordagem do algoritmo a ser utilizado.

Os métodos de segmentação utilizados no estado da arte para segmentação de imagens médicas podem ser dividido nas categorias mostradas na Figura 41 (PATIL; DEORE, 2013; GORDILLO; MONTSENY; SOBREVILLA, 2013).

A Tabela 5 mostra as principais características de cada abordagem. A primeira coluna da Tabela 5 indica a abordagem de segmentação, a coluna 2 descreve as características da abordagem, enquanto que as colunas 3 e 4 descrevem as principais vantagens em desvantagens, respectivamente.

**Figura 41** – Abordagens de segmentação utilizadas em imagens médicas.

Fonte: do autor.

Imagens de mamografia se caracterizam por possuírem regiões não homogêneas, sujeitas a ruídos e com contornos pouco definidos, o que torna o processo de segmentação mais difícil. Desta forma, abordagens baseadas em limiar e baseadas em contorno podem não obter bom desempenho para regiões de lesão com borda indefinida. Métodos que utilizam modelos deformáveis e baseados em região mostram-se bons candidatos para segmentação de lesões, considerando-se as características descritas.

Além dos métodos baseados em região descritos na seção 4.1, destaca-se o método GrowCut, que é um método baseado em autômatos celulares, e que realiza segmentação de forma simples, não paramétrica, baseado na seleção inicial de sementes e em informações locais. Apesar desse método não ter sido aplicado para imagens de mamografia, tem sido utilizado com sucesso em outros problemas de segmentação de imagens médicas (SONG et al., 2015; ELYOR; LEE, 2013; HAMAMCI et al., 2012).

Como definido na seção 1.3, o trabalho proposto tem como objetivo desenvolver um novo método de segmentação de lesão semi-supervisionado. Conforme demonstrado na Tabela 4 os métodos automáticos do estado da arte se baseiam em limiar e apesar de gerarem sementes de forma automática, utilizam métodos que dependem da localização correta das sementes para obter uma segmentação precisa. Visto que os métodos de segmentação interativos são mais confiáveis e obtêm melhor segmentação, tal como apresentado por Veeraraghavan e Miller (2011), o trabalho visa desenvolver um método semi-supervisionado a partir de um método supervisionado, ou interativo. Para a escolha do método, foi feita uma análise dos principais algoritmos de segmentação supervisionados, descritos na Tabela 6. A primeira coluna da Tabela 6 identifica a técnica descrita, a segunda coluna mostra se a técnica possui parâmetros, a terceira indica se o método tem potencial a ser paralelizável, a quarta coluna indica se o método é robusto à bordas irregulares, e por fim, a última coluna indica se o método é robusto à bordas com baixo contraste.

Segundo Zhao e Xie (2013), um método interativo para ser viável para aplicações práticas, deve atender os seguintes critérios: (a) minimizar a interação com o usuário; (b) minimizar o resultado de segmentação entre os usuários; (c) ser computacionalmente

**Tabela 5** – Resumo das principais abordagens de segmentação na área médica.

Abordagem de Segmentação	Característica	Vantagens	Desvantagens
Limiar	Requer que o histograma da imagem tenha um número de vales, cada um corresponde a uma região.	Simples e com baixo custo computacional. Não necessita de conhecimento prévio.	Dificuldade em regiões com baixo contraste. Não considera informações espaciais. Desta forma não garante que regiões segmentadas são contíguas.
Baseados em Região. Normalmente baseados na marcação de sementes iniciais.	Agrupa pixels em regiões homogêneas	Capaz de segmentar regiões com propriedades similares. São mais imunes a ruídos do que abordagens baseadas em contornos.	Em geral, são sequenciais e possuem custo elevado de tempo e recurso computacional. São dependentes da localização das sementes.
Baseado em Contorno	Baseado na detecção de descontinuidades. Normalmente tentam localizar pontos com maior ou menor mudança abrupta na intensidade dos pixels.	Funcionam bem com imagens que possuem bom contraste entre regiões.	Não funciona bem em imagens com contorno pouco definido
Agrupamento	Assume que cada região da imagem forma um agrupamento de características.	Simples implementação. Em geral, não supervisionado.	Determinação do número de clusters Dependente das características a serem utilizadas.
Modelos Deformáveis	Se ajustam a região baseados no contraste da imagem, reajustando a fronteira do objeto de interesse a partir de valores de energia.	Capaz de se ajustar a região de segmentação	O modelo pode convergir para fronteira incorretas, em caso de não homogeneidade. Dificuldade na definição dos melhores parâmetros para o problema.

**Tabela 6** – Principais técnicas de segmentação supervisionadas utilizadas em imagens médicas.

Técnica	Parâmetros	Paralelizável	Robusto à bordas irregulares	Robusto à bordas com baixo contraste
Contornos Ativos	Sim	Sim	Não	Não
Crescimento de Região	Sim	Não	Sim	Não
Graph Cut	Sim	Sim	Sim	Sim
GrowCut	Não	Sim	Sim	Sim
Random Walks	Sim	Sim	Sim	Sim
Line Wire	Sim	Sim	Sim	Sim

rápido; (d) ter potencial de paralelização. De acordo com a Tabela 6, os métodos baseados em contornos ativos e crescimento de região não apresentam facilidade de lidar com

bordas com baixo contraste, o que é uma característica desejável para a segmentação de lesões. Quanto a robustez para lidar com bordas irregulares o método baseado em contornos ativos apresenta dificuldade em lidar com bordas do tipo espiculado. Apesar desse problema poder ser resolvido com um melhor ajuste de parâmetros, esse ajuste torna o método dependente do conhecimento especialista para o bom funcionamento no contexto do problema. Segundo Patil e Deore (2013) Métodos baseados em crescimento de região possuem natureza sequencial, o que pode ser custoso para realizar segmentação em imagens de grande tamanho. A quantidade de parâmetros foi um fator decisivo na escolha do método supervisionado. Naturalmente deseja-se que o método de segmentação possua a menor quantidade de conhecimento especialista possível. Apesar desse métodos já requerem o conhecimento especialista na marcação inicial de sementes, o ajuste ótimo de parâmetros é uma etapa indesejada por tornar o método mais dependente do usuário. Além disso, ao tornar ao automatizar um método supervisionado é provável a inserção de novos parâmetros de ajuste. Desta forma, quanto menor o número de parâmetros que o método de segmentação supervisionado tiver, melhor, desde que possua as características necessárias para realizar uma boa segmentação para o problema. Baseado nesses critérios, identificou-se que o método GrowCut não possui nenhum parâmetro além da seleção inicial de sementes, além de ter características de ser paralelizável e ter potencial para lidar com bordas irregulares e com baixo contraste. Além disso o método tem sido utilizado com sucesso em outros tipos de segmentação de lesão, sendo de fácil implementação e com alto potencial de paralelização.

Apesar da escolha inicial, o método GrowCut nunca havia sido aplicado para segmentação em imagens de mamografia. Desta forma, foi necessário avaliar a viabilidade do método para a segmentação de lesões em imagens de mamografia, verificando a qualidade de segmentação obtida quando comparado à técnicas do estado da arte. A validação do método GrowCut, validado quanto à qualidade de segmentação e comparado com trabalhos da arte será descrito no Capítulo 5.

#### 4.5 CONSIDERAÇÕES DO CAPÍTULO

Neste capítulo foi apresentado o estado da arte de técnicas envolvendo pré-processamento, segmentação e classificação de imagens de mamografia digital. Este trabalho foca na subárea de segmentação de regiões de interesse, analisando técnicas supervisionadas e não-supervisionadas. No entanto, a maioria dos trabalhos não realiza uma análise aprofundada quanto à qualidade da segmentação da técnica quando comparada com a imagem esperada. Sendo esse um dado importante para o diagnóstico final da mamografia, verificou-se que existe uma lacuna em trabalhos com esse tipo de análise. Apesar de existirem muitas técnicas com bons resultados, ainda existe espaço para o desenvolvimento de técnicas mais simples, com menor necessidade de interação com o usuário, maior

desempenho e qualidade de segmentação.

Além disso, foram apresentados algoritmos das principais técnicas do estado da arte para a segmentação de lesões em imagens de mamografia digital. As técnicas supervisionadas ainda requerem um conhecimento especialista alto para identificação da localização da lesão, o que torna o processo custoso. Trabalhos de técnicas não supervisionadas apresentam boa localização da lesão, porém não fazem análise aprofundada quanto a qualidade da segmentação.

## 5 ALGORITMO PROPOSTO

Este capítulo apresenta o algoritmo proposto, que é um algoritmo semi-supervisionado para segmentação de lesões, baseado em modificações nas regras de evolução do algoritmo GrowCut. Inicialmente é realizada a validação do GrowCut como técnica viável para segmentação de lesões, comparando com métodos supervisionados do estado da arte. Em seguida, é apresentado o método proposto, descrevendo as equações envolvidas, assim como o pseudocódigo e as modificações realizadas.

### 5.1 INTRODUÇÃO

Conforme apresentado no capítulo [refch:relatedwork](#), trabalhos do estado da arte mostram que técnicas que envolvem maior conhecimento especialista possuem melhores resultados na qualidade de segmentação de lesões, tais como as técnicas baseadas em sementes (CORDEIRO et al., 2012; ZHENG; LIU; LIU, 2013). As técnicas baseadas em sementes requerem que a rotulação inicial dos *pixels* seja feita pelo usuário, o qual deve ter um conhecimento especialista da região da lesão. No entanto, é desejado minimizar o conhecimento do usuário e obter uma boa qualidade de segmentação. Com base no estudo realizado no capítulo 4, o algoritmo GrowCut mostra-se um candidato interessante para a segmentação de lesões por não possuir parâmetros além das sementes iniciais. No entanto, nenhum trabalho havida sido publicado aplicando o método GrowCut para a segmentação de lesões em imagens de mamografia. Portanto, inicialmente realizamos um estudo de validação do GrowCut, comparando com técnicas supervisionadas utilizadas no estado da arte, para validar se o algoritmo apresenta resultados de segmentação competitivos para o problema. Esse estudo foi realizado para verificar se a qualidade de segmentação obtida em outras aplicações, tais como as aplicadas por Phan e Androutsos (2011) e por LU e CHEN (2014), se mantinha para a segmentação de lesões.

Após a etapa de validação, este trabalho propõe e avalia um novo modelo para segmentação de lesões de imagens de mamografia, baseado no modelo de segmentação por sementes, mas que seja automático e independente do usuário, uma vez selecionada uma região de interesse. Para isso, é utilizado um modelo baseado em sementes e um modelo de pertinência da região de lesão. O estudo do algoritmo GrowCut é realizado a seguir.

### 5.2 ESTUDO DO ALGORITMO GROWCUT

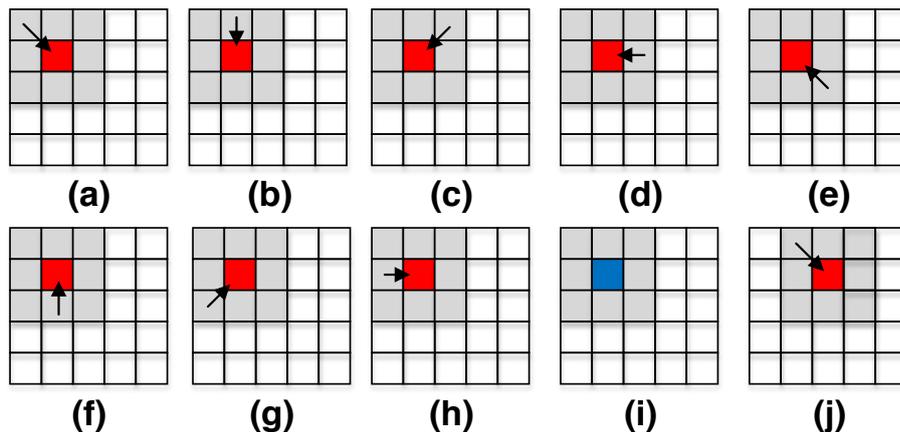
#### 5.2.1 Descrição do GrowCut

O GrowCut é uma técnica baseada em mecanismos de autômatos celulares, descrito por Hernandez e Herrmann (1996), os quais são representados por uma grade de células,

onde cada célula tem um número finito de estados, que podem variar de acordo com as regras de vizinhança. A vizinhança consiste de uma seleção de *pixels* vizinhos em uma imagem, podendo ser usado os modelos de vizinhança tais como os de Neumann e Moore (NAYAK et al., 2014), por exemplo. Todas as células atualizam seus estados de acordo com a mesma regra de atualização, baseadas nos valores das células vizinhas. Cada vez que uma regra é aplicada à grade toda, uma nova iteração começa.

No GrowCut, cada célula tem valor de força associado e, a cada iteração, sua vizinhança tenta dominá-la, mudando seu rótulo. Se a célula defensora tiver maior força do que a dominante, então a unidade defensora continua com o mesmo rótulo. Caso contrário, o elemento recebe o rótulo do vizinho dominante. O processo continua até que o algoritmo convirja, isto é, todas as células parem de mudar seus estados. A Figura 43 mostra esse processo.

**Figura 42** – Ataque à uma célula defensora, em vermelho, por sua vizinhança, em cinza. A célula defensora assume o rótulo do vizinho mais forte. O processo é repetido por todas as células da matriz.

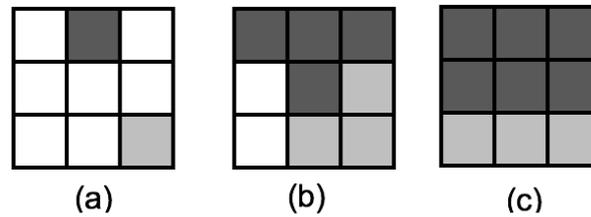


Fonte: do autor.

Na Figura 42, a célula defensora é representada em vermelho, enquanto sua vizinhança é mostrada em cinza. Cada vizinho do elemento defensor tenta dominá-lo. Esse ataque é baseado na força de cada célula e na diferença de valores de intensidade de pixel entre atacante e defensor. Da Figura 42 (a) até a Figura 42 (h), é mostrado cada vizinho realizando o ataque. Quando uma célula atacante domina com sucesso o vizinho defensor, o elemento atacado passa a ter o mesmo rótulo do atacante, mas a nova força é baseada na regra de atualização de evolução, a qual é descrita nessa seção. A Figura 42 (i) mostra a mudança de rótulo do defensor. Por fim, a Figura 42 (j) mostra o começo do processo com outra célula. Esse processo é realizado com todos os elementos da matriz. O processo de evolução é realizado através de iterações, nas quais todos os elementos da matriz agem como células defensoras sendo atacadas pela vizinhança. Dentro da mesma iteração o processo é realizado em paralelo. A Figura 43 mostra a evolução das células na técnica

GrowCut, em diferentes iterações dentro do processo de evolução.

**Figura 43** – Evolução das células no GrowCut



Fonte: do autor.

A Figura 43 (a) mostra o estágio inicial, com dois *pixels* sementes rotulados. Cada *pixel* semente tem um valor máximo de força, porque é assumido que o usuário tem certeza do rótulo daquele *pixel*. Cada semente deve ter a característica de estar próximo à borda da área de segmentação desejada. Além disso, cada *pixel* semente recebe um rótulo indicado pelo usuário como sendo um semente de região de fundo ou de objeto. Portanto, o posicionamento correto das sementes é importante para o GrowCut. A quantidade de sementes necessária para realizar a segmentação varia de acordo com o problema. O estudo da quantidade de sementes será realizado neste capítulo. No exemplo da Figura 43 são mostradas apenas duas sementes, com um rótulo de cada classe, apenas para fins de simplificação. Porém geralmente um maior número de sementes é necessário. Pixels sem rótulo têm força zero, sendo representados como células brancas na Figura 43, e são facilmente dominados. Nas iterações seguintes, os *pixels* semente propagam seus rótulos e as células dominadas herdam o rótulo do atacante, representado pela Figura 43 (b), mas recebem valor de força menor. O sucesso da dominação é baseado na força e intensidade de pixel das células vizinhas. Esse processo continua até o algoritmo convergir. No estágio final, representado pela Figura 43 (c), as células não mudam mais seus rótulos e o algoritmo termina, retornando a imagem segmentada. Pode-se dizer que o algoritmo sempre converge, pois a força propagada entre as células sempre é menor ou igual à força da célula transmissora, de forma que a força propagada tende a diminuir com as iterações. Quando não há mais propagação o algoritmo converge.

O algoritmo GrowCut recebe como entrada a imagem a ser segmentada e uma matriz de rótulos com os rótulos fornecidos pelo usuário, os quais podem ser de dois tipos: rótulo de fundo da imagem e rótulo de objeto, que correspondem às regiões fora e dentro da lesão, em imagens de mamografia. Inicialmente a matriz possui células sem rótulos atribuídos. Quando o usuário determina rótulos de fundo e de objeto, as células rotuladas começam a interagir com a vizinhança, atribuindo novos rótulos. O pseudocódigo do GrowCut é descrito no Algoritmo 2.

Inicialmente, para cada célula  $p$  em um espaço  $P$  de células, que corresponde aos *pixels* da imagem, se o valor do rótulo de uma célula  $p$ , representada por  $l_p$  for rotulada pelo

**Pseudocódigo 2** Regra de evolução do GrowCut

---

```

1: procedure GROWCUT( $P, l$ )
2:   for all  $p \in P$  do
3:     if  $l_p = l_{obj}$  or  $l_p = l_{bg}$  then
4:        $\Theta_p = 1$ 
5:     else
6:        $\Theta_p = 0$ 
7:     end if
8:   end for
9:   for all  $p \in P$  do
10:     $l_p^{t+1} \leftarrow l_p^t$ 
11:     $\Theta_p^{t+1} \leftarrow \Theta_p^t$ 
12:    for all  $q \in N(p)$  do
13:      if  $g(\|\vec{C}_p - \vec{C}_q\|_2) \cdot \Theta_q^t > \Theta_p^t$  then
14:         $l_p^{t+1} \leftarrow l_q^t$ 
15:         $\Theta_p^{t+1} \leftarrow g(\|\vec{C}_p - \vec{C}_q\|_2) \cdot \Theta_q^t$ 
16:      end if
17:    end for
18:  end for
19:  return  $l$ 
20: end procedure

```

---

usuário com um rótulo de objeto ou fundo, representado como  $l_{obj}$  e  $l_{bg}$ , respectivamente, a força da célula  $p$ , representada por  $\Theta_p$ , é igual a 1, caso contrário é igual a 0. Em seguida, para cada célula  $p$  em um espaço  $P$  de células, é feita a cópia do estado anterior, atualizando o valor do rótulo da célula  $p$  na iteração  $t+1$ , representada por  $l_p^{t+1}$ , e o valor de força da célula  $p$  na iteração  $t+1$ , como as  $\Theta_p^{t+1}$ . Em seguida, para cada célula  $q$  pertencente à vizinhança da célula  $p$ , representada como  $N(p)$ , a condição de atualização de rótulo é checada. Na condição da linha 13,  $\vec{C}_p$  e  $\vec{C}_q$  são vetores tridimensionais dos *pixels*  $p$  e  $q$  no espaço de cores RGB, respectivamente, e  $\Theta_q^t$  e  $\Theta_p^t$  são valores de força das células  $q$  e  $p$  na iteração  $t$ . Originalmente, o GrowCut foi criado para segmentar imagens coloridas, por isso  $\vec{C}_p$  representa o vetor de valores de intensidade do *pixel*  $p$  na escala RGB. Porém, para mamogramas, cujas imagens são em tons de cinza,  $\vec{C}_p$  representa o valor de intensidade, em tons de cinza, do *pixel*  $p$ . A notação original foi mantida para fins de generalização e para mostrar o potencial do GrowCut para segmentação de imagens médicas coloridas. No entanto, para uso em imagens de mamografia, cujas imagens são em tons de cinza, foi utilizado o nível de intensidade do *pixel* ao invés do vetor tridimensional. A condição da linha 13 avalia se os *pixels* vizinhos possuem valor de intensidade de *pixel* próximo e diferença de força alta. Caso isso ocorra, a célula que está sendo atacada receberá uma parte da força do vizinho atacante, assim como seu rótulo. A função  $g$ , nas linhas 13 e 15, é uma função monotônica decrescente. A função  $g$  é responsável por ajustar a força das células atualizadas baseado na diferença de intensidade entre os valores das células

vizinhas, de acordo com a Equação 5.1:

$$g(x) = 1 - \frac{x}{\max \|\vec{C}\|_2}, \quad (5.1)$$

onde a variável  $x$  representa a diferença de intensidade de *pixel* entre duas células e  $\max \|\vec{C}\|_2$  é o valor máximo de intensidade do conjunto de todos os vetores de valores de intensidade de *pixels* presentes da imagem. O intervalo de valores da variável independente  $x$  está dentro do intervalo  $[0,255]$ , pois é o intervalo de diferença de valores de intensidade entre dois *pixels*. Desta forma, a função  $g$  recebe como entrada a diferença de intensidade entre células vizinhas, representada pelo variável  $x$ , e é dividida pelo valor de intensidade máximo presente imagem. Quanto menor o valor de  $x$ , mais próximo de 1 será o valor de  $g(x)$ . Isso indica que células com valor próximos de intensidade de *pixel* têm maior força na propagação informação entre si do em que entre células com diferença de intensidade alta. A função  $g$  é função utilizada no GrowCut original e mantida na abordagem proposta. No entanto, uma análise utilizando diferentes funções pode ser feita em trabalhos futuros.

Por fim, o rótulo e a força das células são atualizadas se a regra de dominação é satisfeita, e o processo se repete até o algoritmo convergir.

### 5.2.2 Análise de Segmentação de Lesões utilizando o GrowCut Clássico

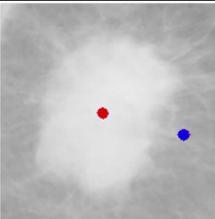
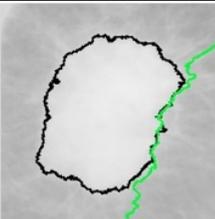
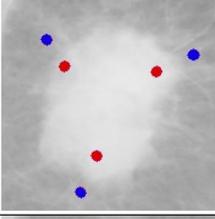
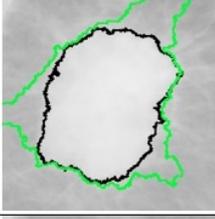
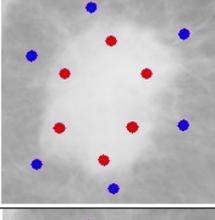
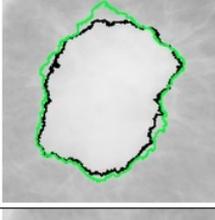
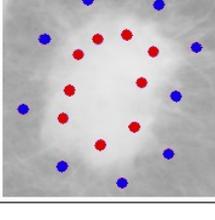
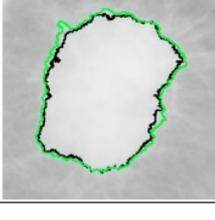
A fim de avaliar o desempenho da técnica GrowCut, o conjunto de 57 imagens da base de dados Mini-MIAS foi selecionado para análise. Para cada imagem, foi selecionada uma região de interesse, de forma manual, baseada nas indicações de localização de lesão fornecidas pela própria base. Para cada imagem foi definida uma imagem ouro, realizada manualmente, também baseada nas indicações fornecidas pela base.

A primeira análise foi realizada com o intuito de avaliar o comportamento da relação entre a quantidade de sementes na técnica GrowCut e o impacto na qualidade da segmentação. Para esse propósito, quatro casos foram estudados: selecionar 1, 3, 6, e 9 sementes, para cada classe de segmentação (lesão e não-lesão). A Figura 44 mostra os resultados desse experimento, para a imagem mdb184.

A primeira coluna da tabela mostra a quantidade de pontos para cada classe: lesão e não-lesão. A segunda coluna mostra os pontos selecionados, onde os pontos em azul são os pontos externos à lesão e os vermelhos são os pontos internos. A terceira coluna mostra a comparação entre o contorno da segmentação obtida através da aplicação da técnica GrowCut, representada pela linha verde, e o contorno da imagem ouro, representada pela linha preta.

Para os resultados apresentados na Figura 44, para o primeiro caso, foi possível observar que selecionar apenas um ponto interno e outro externo à lesão não é o suficiente

**Figura 44** – Comparação da qualidade de segmentação baseada no número de sementes, para a imagem mdb184.

Número de Pontos	Pixels semente	Comparação dos Contornos
1 ponto		
3 pontos		
6 pontos		
9 pontos		

Fonte: do autor.

para se obter uma boa segmentação. Quando a quantidade de pontos é aumentada para 3, como no segundo caso da mesma tabela, a segmentação melhora, mas ainda há alguns contornos mal definidos. No entanto, quando são selecionados 6 pontos, como no terceiro caso, a segmentação se aproxima mais da imagem ouro. Ao aumentar o número de pontos para 9, a segmentação melhora um pouco mais, porém o esforço de selecionar mais pontos pode não valer a pena em alguns casos. Embora a Figura 44 seja apresentada a análise apenas para a imagem mdb184, o procedimento foi realizado para todas as imagens da base Mini-MIAS. Na maioria das imagens testadas, selecionar 6 pontos internos e 6 externos à região de lesão foi o suficiente para alcançar uma boa relação entre esforço de seleção de pontos e boa segmentação. Para analisar a qualidade de segmentação baseada na quantidade de pontos, foram utilizadas as métricas de erro de Área, Fator de Forma, Perímetro, Distância de *Feret* e Solidez. A Tabela 7 mostra a média de valores dessas métricas, para todas as imagens analisadas.

**Tabela 7** – Média de erro das métricas analisadas, quando usados 1, 3, 6 e 9 pontos.

Pontos	$E_{\text{Área}}$	$E_{\text{Per}}$	$E_{\text{FX}}$	$E_{\text{FY}}$	$E_{\text{Solidez}}$
1	0,8025	0,3189	0,3996	0,4063	0,0898
3	0,2925	0,1677	0,2264	0,1950	0,0667
6	0,1590	0,1975	0,1242	0,1081	0,0461
9	0,1298	0,1951	0,1084	0,1025	0,0461

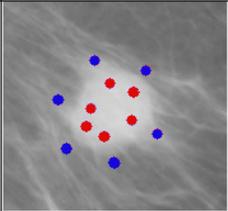
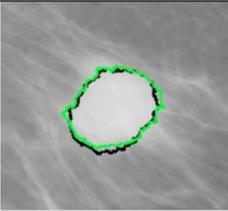
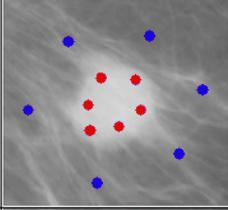
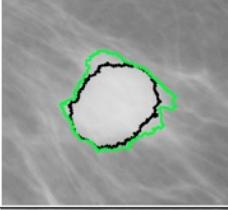
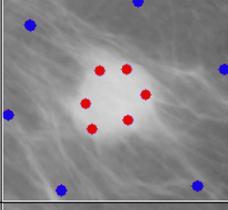
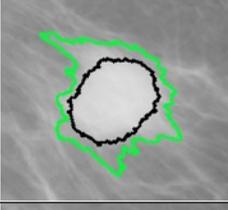
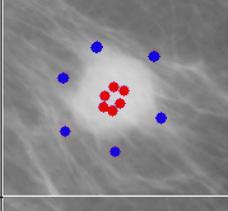
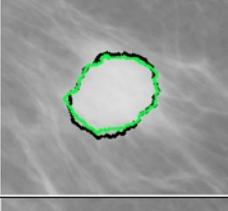
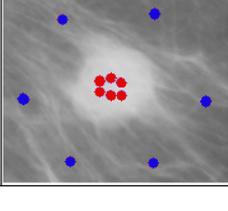
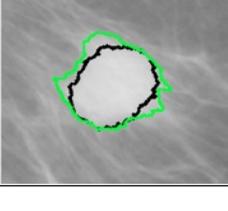
Conforme pode ser visto na Tabela 7, a média de erro diminui à medida que aumentam o número de pontos. Apesar do erro de perímetro ser menor com usando 3 pontos, a maioria dos erros diminuem quando se aumenta a quantidade de pontos. No entanto, a diminuição entre 6 e 9 pontos é pequena considerando o aumento de conhecimento especialista necessário para a seleção. Baseado nesse estudo, foram usados 6 pontos de seleção de sementes internas e externas à região de interesse para as análises seguintes. Contudo, o número de pontos pode ser ajustado baseado na complexidade de cada imagem ou problema.

A segunda análise foi direcionada para observar o impacto da localização dos pontos na qualidade da segmentação. Essa análise é mostrada na Figura 45. O primeiro cenário foi feito selecionando os pontos internos e externos próximos das bordas da lesão. Esse cenário provê uma boa segmentação com essa seleção. No segundo caso os pontos externos estão um pouco mais afastados das bordas da lesão. O resultado é que a segmentação tem sua qualidade diminuída, mas ainda é próxima do contorno da imagem ouro. Se os pontos externos são colocados ainda mais distantes, como no caso 3, a precisão da técnica não é tão boa. Nos casos 4 e 5, as distâncias dos pontos internos são alteradas, mantendo os pontos externos mais perto e em uma distância média, respectivamente.

Baseado nos resultados da Figura 45, onde foi analisado o impacto da distância dos pontos selecionados em relação à borda da lesão, conclui-se que quanto mais próximos os pontos externos estiverem da borda da lesão, melhor é o resultado da segmentação do GrowCut. Por outro lado, conclui-se também que a distância dos pontos internos não tem tanto impacto quando a distância dos pontos externos em relação a borda da lesão. Na maioria dos casos analisados, onde a lesões eram pequenas, a localização interna das sementes não tinha muita influência. Porém, em alguns casos, tais como lesões grandes ou casos com borda pouco definida, a localização dos pontos internos pode ter um impacto significativo. Para a maioria dos casos é mais fácil selecionar os pontos centrais internos e os externos próximos à borda. Esse tipo de seleção é o suficiente para atingir uma boa qualidade na segmentação, como verificado nos casos analisados. No entanto, o método depende crucialmente de uma atribuição inicial, a qual deve ser feita por um especialista.

A próxima análise é feita comparando-se a segmentação do GrowCut com a da imagem ouro. A Figura 46 mostra 5 casos de segmentação bem sucedidas. A primeira

**Figura 45** – Análise da distância entre as sementes e as bordas da lesão, para a imagem mdb028.

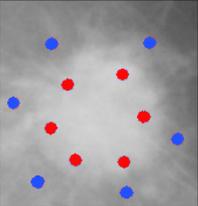
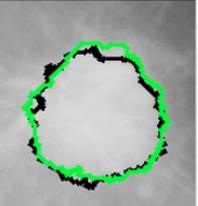
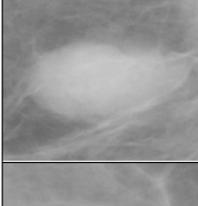
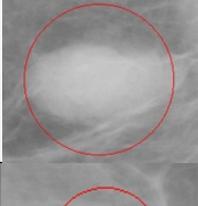
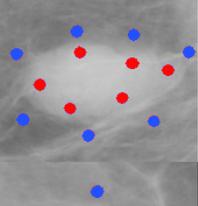
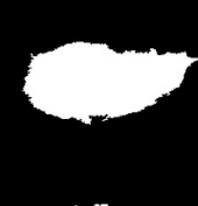
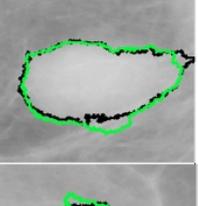
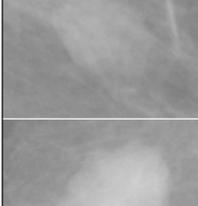
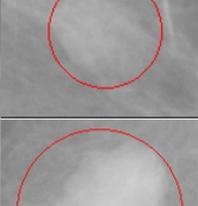
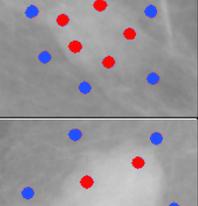
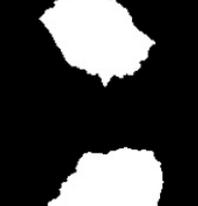
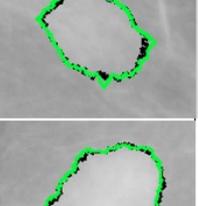
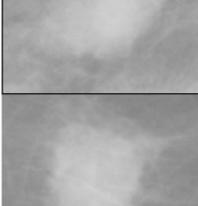
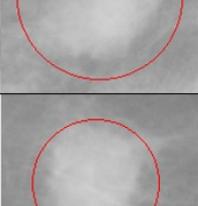
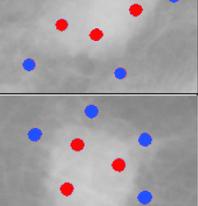
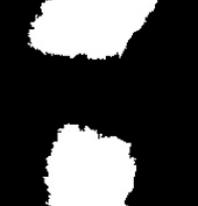
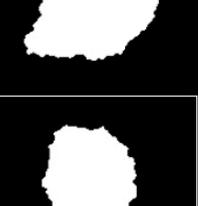
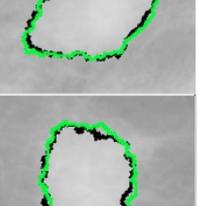
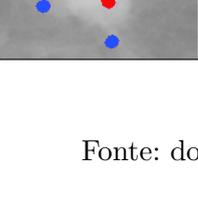
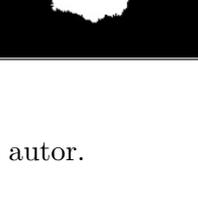
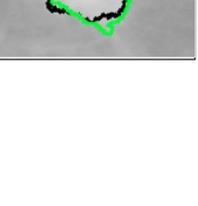
Número do Caso	Pixels Semente	Comparação dos Contornos
1		
2		
3		
4		
5		

Fonte: do autor.

coluna da tabela indica o nome da imagem na base de dados Mini-MIAS. A segunda coluna fornece a região de interesse da imagem original e a terceira coluna mostra a indicação de lesão da base de dados, representado como um círculo vermelho, enquanto que a quarta coluna mostra os pontos de semente selecionados para a aplicação da técnica. Na quarta coluna da Figura 46, os pontos de semente externos são marcados em azul, enquanto que os internos são marcados em vermelho. Em média, é necessário selecionar por volta de 6 pontos externos e 5 internos, o que soma um total de 11 pontos. No entanto, a quantidade de pontos necessários pode variar dependendo da complexidade da segmentação. Selecionar mais pontos torna a segmentação mais precisa, porém requer mais esforço selecionando-as. Na quinta coluna da Figura 46 é mostrada a imagem ouro da segmentação da lesão. Essa

imagem ouro foi construída encontrando-se o melhor limiar para cada imagem. A sexta coluna representa o resultado da segmentação da técnica GrowCut. A segmentação é feita automaticamente uma vez que tenham sido fornecidas as sementes da coluna quatro. Por fim, a última coluna representa a comparação entre os contornos da segmentação do GrowCut, em verde, e o contorno da imagem ouro, em preto.

**Figura 46** – Comparação entre a segmentação da técnica GrowCut e a imagem ouro, para as imagens mdb202, mdb025, mdb012, mdb015 e mdb134.

Imagem Original	Indicação no Mini-Mias	Pontos Seleccionados	Imagem Ouro	Imagem Segmentada	Comparação dos Contornos
					
					
					
					
					

Fonte: do autor.

A partir da Figura 46 é possível observar que os contornos da segmentação do GrowCut são bem próximos aos do contorno das imagens ouro. A mesma qualidade de resultados encontrada nessa análise pôde ser verificada na maioria das imagens selecionadas da base de dados. Além disso, foi possível observar que todas as imagens segmentadas se encontraram dentro das regiões indicadas pela base de dados. Até as imagens que são mais difíceis de segmentar, devido à baixa densidade da lesão ou por causa da baixa qualidade

da imagem, a técnica foi capaz de fornecer uma segmentação próxima da imagem ouro. Esse fato ocorre porque o usuário fornece uma informação inicial da região de lesão e não-lesão, através da seleção de sementes, e isso é o suficiente para que a técnica segmente a região automaticamente. Apesar de a seleção de sementes para a segmentação do GrowCut requerer pouco esforço do usuário, as sementes selecionadas precisam estar próximas da região esperada para que a técnica forneça uma boa segmentação.

Os casos analisados até então foram também avaliados estatisticamente comparando-os através das métricas de Área, Perímetro, Fator de Forma, Distância de *Feret* e Solidez. Para cada métrica foi calculado um erro estimado, comparando a métrica da imagem segmentada e a imagem ouro. O erro estimado é calculado através da Equação 6.4, descrita no capítulo 6. A Tabela 8 mostra os resultados dos erros estimados das imagens apresentadas na Figura 46.

**Tabela 8** – Erros estimados para as métricas de Fator de Forma, Área, Perímetro, Distância de *Feret* e Solidez.

	<b>mdb202</b>	<b>mdb025</b>	<b>mdb012</b>	<b>mdb015</b>	<b>mdb134</b>
<b>Fator de Forma</b>	0,194	0,352	0,129	0,399	0,371
<b>Área</b>	0,133	0,071	0,220	0,025	0,059
<b>Perímetro</b>	0,030	0,126	0,184	0,161	0,138
<b>FeretX</b>	0,149	0,037	0,328	0,052	0,014
<b>FeretY</b>	0,027	0,119	0,192	0	0,067
<b>Solidez</b>	0,012	0,015	0,130	0,001	0,019

Na Tabela 8, em todos os casos os erros apresentados foram próximos a zero, para as seis métricas analisadas. O fator de forma representa a similaridade do formato da segmentação, o que ocorreu em todos os casos, como mostrado na Figura 46. A Área, calculada em *pixels*, mostra a correspondência entre a segmentação e a imagem ouro. O mesmo ocorre com as métricas de Perímetro, Distância de *Feret* e Solidez.

Os resultados de erros médio, máximo, mínimo e desvio padrão foram observados

**Tabela 9** – Resultados de erro médio, máximo, mínimo e desvio padrão para todas as imagens analisadas.

	<b>Média</b>	<b>Máximo</b>	<b>Mínimo</b>	<b>Desvio Padrão</b>
<b>Fator de Forma</b>	0,334	0,980	0,001	0,245
<b>Área</b>	0,188	0,956	0,009	0,199
<b>Perímetro</b>	0,216	0,931	0,016	0,187
<b>FeretX</b>	0,157	0,809	0,013	0,161
<b>FeretY</b>	0,166	0,685	0	0,165
<b>Solidez</b>	0,082	0,309	0,001	0,072

para todo o conjunto de imagens analisadas, como mostrado na Tabela 9. Na Tabela 9 foi mostrado que o erro médio da segmentação e desvio padrão próximos de zero, indicando similaridade entre o valor da métrica aplicada para a região segmentada e a imagem ouro. Para todas as imagens testadas da base de dados, o erro estimado foi próximo de zero, para a maioria das métricas analisadas. Isso significa que a técnica é capaz de alcançar uma similaridade representativa em termos de área, perímetro e forma, o que indica que é uma boa solução para um método semi-automático de segmentação, pois a similaridade entre as métricas indica que a segmentação obtida pelo método foi próxima da desejada. É importante notar que o erro médio pode ser ainda mais reduzido se a quantidade de sementes selecionadas do GrowCut é aumentada, aumentando assim a qualidade da segmentação, mas também a subjetividade na marcação e custo de processamento.

A Tabela 10 mostra os resultados obtidos para as métrica AOM, sensibilidade, especificidade e BAC, para todas as imagens analisadas. Para a Tabela 10, quanto maiores os valores obtidos, melhor o resultado.

**Tabela 10** – Resultados da média, valor máximo, mínimo e desvio padrão para as métricas AOM, sensibilidade, especificidade e BAC, para todas as imagens analisadas.

	Média	Máximo	Mínimo	Desvio Padrão
<b>AOM</b>	0,729	0,945	0,240	0,143
<b>Sensibilidade</b>	0,956	1	0,838	0,042
<b>Especificidade</b>	0,903	1	0,706	0,084
<b>BAC</b>	0,920	0,998	0,679	0,069

Como se pode observar na Tabela 10, os resultados obtido com o GrowCut encontram-se próximos de 1, para as métricas analisadas, indicando ser um algoritmo com baixos erros de segmentação para imagens de mamografia.

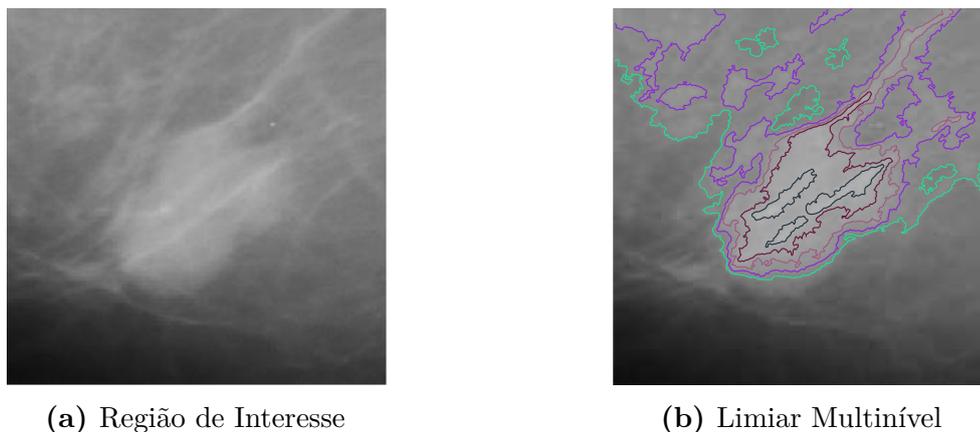
### 5.2.3 Extensão Proposta do GrowCut

Após realizar a análise da segmentação da técnica GrowCut para imagens de mamografia digital, foi realizada uma extensão desse modelo para realizar uma segmentação automática a partir de uma região de interesse, sem a necessidade do conhecimento especialista para a seleção de sementes iniciais. Esse modelo proposto é um modelo híbrido realizado pela junção da abordagem Topográfica de segmentação de lesões (HONG; SOHN, 2010), descrito no capítulo 4, e o GrowCut clássico. O objetivo do estudo é criar uma extensão semi-supervisionada do GrowCut, de forma semelhante ao que os trabalhos do estado da arte fazem, para avaliar e identificar problemas nessa metodologia. Conforme descrito no capítulo 4, alguns métodos automáticos de segmentação utilizam uma etapa automática para seleção de sementes, e em uma segunda etapa utilizam as sementes geradas em um método supervisionado. Na extensão proposta nesse estudo, é utilizada a abordagem Topográfica para geração de sementes, as quais são utilizadas como entrada

para o GrowCut. Chamamos a abordagem híbrida desenvolvida de GrowCut Topográfico (*Topographic GrowCut*, TGC), a qual é descrita a seguir.

A extensão do GrowCut também é uma abordagem nova desenvolvida neste trabalho, a fim de evitar a necessidade de interação com o usuário para realizar uma boa segmentação. Nesta abordagem, o usuário seleciona apenas a área de interesse de segmentação, onde é necessário apenas um conhecimento aproximado da localização da lesão, e a segmentação é realizada automaticamente. Não há a necessidade de identificar *pixels* semente nesse método de segmentação, onde seria necessário um maior conhecimento especialista sobre a localização do contorno da lesão.

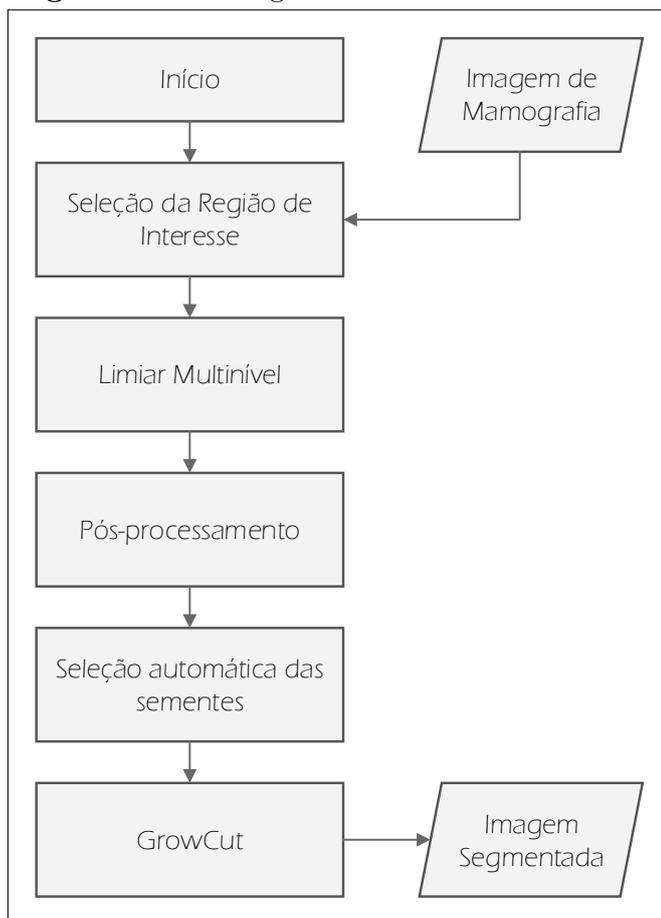
Conforme mencionado, o TGC proposto é uma técnica híbrida baseada no GrowCut e a Abordagem Topográfica, que utiliza limiares multinível. Nesta abordagem, inicialmente a imagem de mamografia é submetida a diferentes níveis de limiar a fim de identificar regiões concêntricas. Uma das propriedades identificadas é que normalmente as lesões se localizam nessas regiões concêntricas, assim como mostrado na Figura 47. Os parâmetros usados para a etapa de limiar multinível foram os mesmos usados no trabalho de Hong e Sohn (2010).



**Figura 47** – Aplicação do Limiar Multinível em um região de interesse

Após aplicados os limiares, são obtidas diferentes camadas binarizadas. Cada camada com regiões concêntricas são consideradas como regiões de lesão, enquanto regiões sem camadas concêntricas são descartadas. Com isso, a pré-seleção da região da lesão é obtida, tendo assim uma segmentação prévia da região de seleção. Contudo, a área da lesão normalmente não fica bem segmentada e então a técnica GrowCut é aplicada para melhorar o contorno da segmentação. O fluxograma do TGC é mostrado na Figura 48.

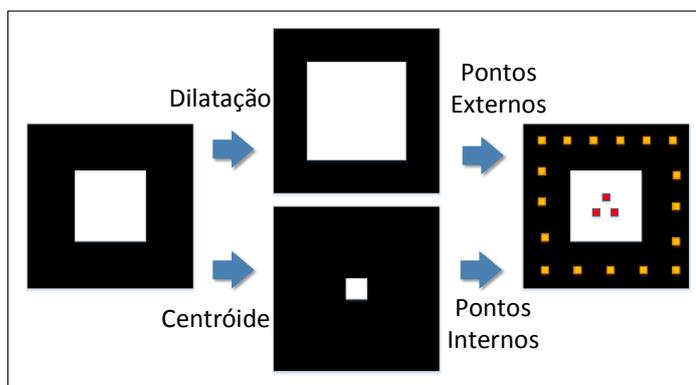
Conforme ilustrado na Figura 48, o primeiro passo do TGC é a seleção da região de interesse, pelo especialista. No trabalho realizado, foi observado que o TGC tem um desempenho melhor quando a região de interesse (ROI) não é muito maior que a região de lesão. Sendo assim, é recomendado que seja selecionada uma região com aproximadamente a área da lesão. Após a região de interesse ter sido escolhida, o limiar multinível é aplicado

**Figura 48** – Fluxograma do GrowCut Estendido.

Fonte: do autor.

para identificar automaticamente a área aproximada da lesão. Em seguida, é feito o pós-processamento na segmentação resultante para eliminar ruídos. Esse pós-processamento é baseado no tamanho de região da lesão gerada pelo limiar multinível. Apenas a região com maior área na região de interesse é mantida. Depois disso, o processo automaticamente inicia a segmentação usando o GrowCut. Como descrito anteriormente, no GrowCut original é necessário que o usuário selecione as sementes para iniciar a segmentação. Nessa seleção é solicitada a identificação dos pontos internos e externos à área a ser segmentada. No TGC, entretanto, esse processo de seleção de sementes é feito automaticamente pelo TGC. Para selecionar as sementes externas da região de interesse da imagem pós-processada, de forma automática, é utilizado o operador morfológico de dilatação. Com esse operador obtêm-se uma área maior do que a área obtida pelo limiar multinível. Toda a área externa da região de lesão obtida através da dilatação irá compor as sementes de classe de fundo para ser utilizado no GrowCut. Para identificar as sementes internas, da classe de lesão, é utilizado o centróide da região. Para os pontos internos não foi usada a região interna inteira, mas sim o centróide da região. Inicialmente testou-se o operador de erosão para identificar os pontos internos, mas o cálculo do centróide, utilizando o centro de massa da

região, apresentou melhores resultados, pois desta forma havia menor chance de semente da classe de lesão ser posicionada incorretamente. A partir do centróide é utilizada a vizinhança  $3 \times 3$ , definida empiricamente, para compor o conjunto de sementes internas. O processo de seleção automática das sementes é ilustrado na Figura 49.



**Figura 49** – Seleção automática de sementes internas e externas.

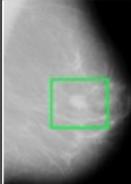
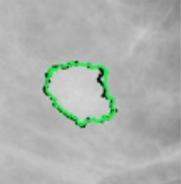
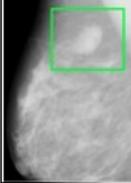
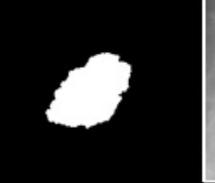
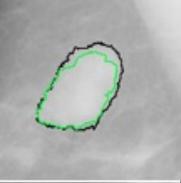
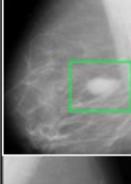
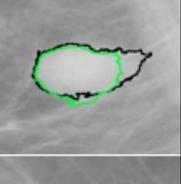
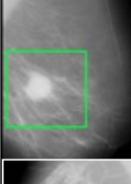
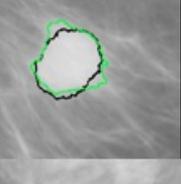
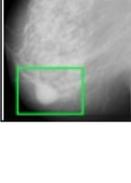
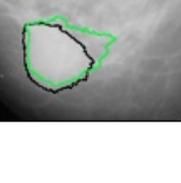
Depois das sementes terem sido automaticamente selecionadas, o GrowCut é iniciado, fornecendo ao término a imagem segmentada. A qualidade da segmentação depende da seleção das sementes. Como a seleção é realizada automaticamente, é esperado que ela não seja tão precisa quanto a seleção manual, supervisionada, como no GrowCut original. No entanto, o processo automático fornece uma boa qualidade de segmentação, próximo da seleção manual, o que é mostrado no capítulo de resultados.

#### 5.2.4 Análise do GrowCut Topográfico

A análise do GrowCut Topográfico foi aplicada ao mesmo conjunto de imagens usado na técnica GrowCut. Foi realizada uma análise qualitativa e quantitativa a fim de observar o desempenho da segmentação do TGC. A análise qualitativa é mostrada na Tabela 11. A Tabela 11 é dividida em 6 colunas, cada uma mostrando uma etapa do processo, e várias linhas, onde cada linha representa uma imagem diferente. A primeira coluna mostra a região que o usuário selecionou a partir da imagem original. As colunas de 2 a 6 mostram apenas a região de interesse selecionada pelo usuário, não da imagem toda. As imagens da coluna 2 representam o resultado da segmentação após o limiar multinível. Como pode ser visto, o limiar não fornece uma segmentação perfeita.

Após a segmentação do limiar multinível, existem algumas extensões e ilhas que precisam ser removidas na imagem. A partir dessa imagem, obtida pelo limiar, apenas a região com maior área é mantida. Em seguida, é realizado o processo de dilatação para identificar os *pixels* semente externos à lesão e é calculado o centróide para identificar as sementes internas. O resultado da seleção automática das sementes é mostrado na coluna 3. A área em preto representa as sementes externas à lesão, que são os *pixels* classificados com o rótulo de não-lesão. A área em branco representa os *pixels* que são identificados como

**Tabela 11** – Comparação entre a segmentação do GrowCut Topográfico e a imagem ouro, para as imagens mdb202, mdb025, mdb012, mdb015 e mdb134.

Seleção da ROI	Resultado do Limiar Multinível	Pixels Semente Gerados Automaticamente	Imagem Ouro	Imagem Segmentada	Comparação dos Contornos
					
					
					
					
					

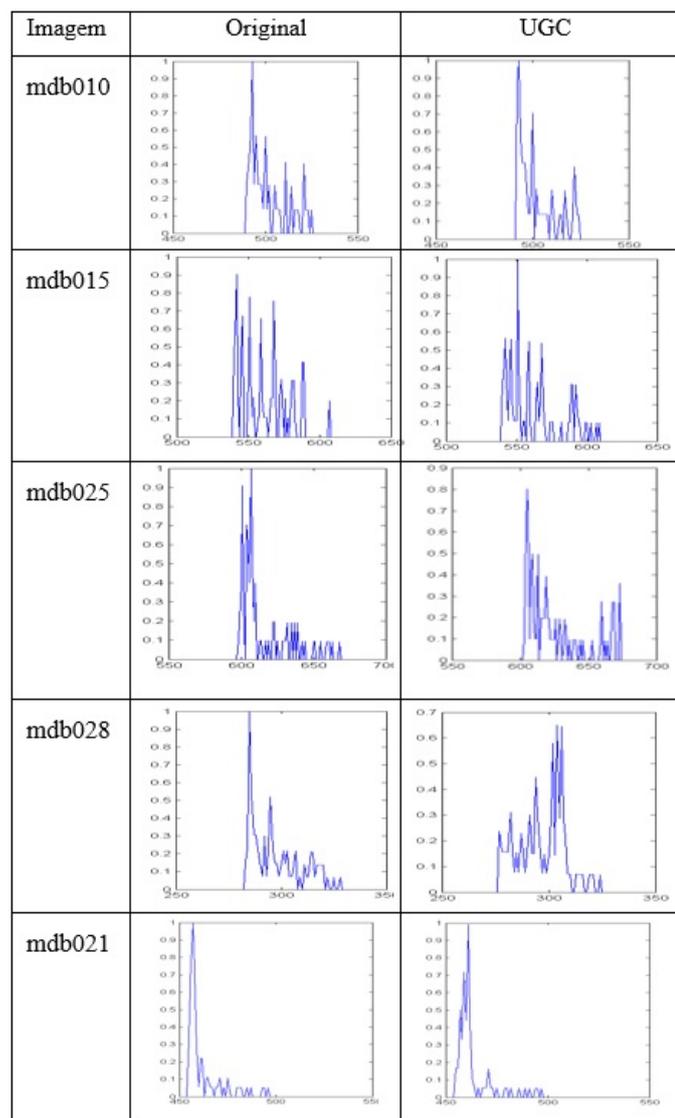
internos à lesão, que são os *pixels* rotulados como lesão. A área em cinza corresponde aos *pixels* que não estão rotulados ainda e que serão rotulados após a aplicação do GrowCut. Os *pixels* rotulados inicialmente servem de entrada ao mecanismo GrowCut. As colunas 4 e 5 mostram a imagem ouro e a segmentação do TGC, respectivamente. A última coluna mostra a comparação entre os contornos da imagem ouro, representado pela linha preta, e a segmentação do TGC, representado pela linha verde.

Quando analisamos o GrowCut Topográfico, a Tabela 11 mostra que a segmentação final chega próxima do contorno esperado pela imagem ouro. Para uma técnica semi-supervisionada esse é um resultado bastante interessante, uma vez que elimina a necessidade de interação com o usuário no GrowCut original. No entanto, a qualidade da segmentação não é tão precisa, em termos de proximidade do contorno da imagem ouro, quanto a do GrowCut Supervisionado. Isso acontece porque a seleção de sementes é feita

automaticamente e pode não ficar próxima o bastante das bordas da lesão. Além disso, o GrowCut requer que a posição inicial das sementes seja precisa, o que não é garantido de geração de sementes do TGC, assim como nos métodos não supervisionados do estado da arte.

Outra análise foi realizada aplicando o *Slope Spectrum Pattern* (TOUDJEU et al., 2008), que ilustra o formato da lesão através da assinatura da imagem. Caso duas imagens tenham um Espectro Padrão similar, isso significa que eles possuem forma similar (TOUDJEU et al., 2008). Esse estudo foi realizado para todas as imagens e na maioria dos casos as imagens segmentadas apresentaram um Espectro Padrão similar aos das segmentações da imagem ouro. O resultado da métrica *Slope Pattern* obtidas pelas segmentações da Tabela 11 é apresentado na Tabela 12.

**Tabela 12** – Comparação do *Slope Spectrum Pattern* da imagem ouro e do GrowCut Topográfico.



A partir da Tabela 12 foi possível observar que o *Slope Spectrum Pattern* entre a imagem ouro e a imagem segmentada são bem próximos. Esse resultado significa que o contorno da imagem segmentada e da imagem ouro são próximos, o que acontece na maioria dos casos.

Por fim, foi utilizado o teste do sinal ranqueado de Wilcoxon (SAMUELS; WITMER; SCHAFFNER, 2012) para cada par de imagem segmentada e imagem ouro, comparando o a distribuição do Espectro Padrão. O teste foi aplicado ao conjunto todo, utilizando um índice de confiança de 0,05. A hipótese nula foi que cada par de uma amostra era igual. Um total de 63% das imagens passaram no teste e não tiveram a hipótese nula rejeitada. Os resultados, incluindo *p-value*, valor mínimo, máximo e desvio padrão são mostrados na Tabela 13.

**Tabela 13** – Resultados do teste do sinal ranqueado de Wilcoxon aplicado ao GrowCut Topográfico.

p-value médio	#Hipóteses Nula Rejeitadas	#Hipóteses Nula Não Rejeitadas	p-value mínimo	p-value máximo	Desvio Padrão
0,3561	21	36	6,46 e-010	0,9875	0,2955

A partir dos resultados do teste de Wilcoxon, na Tabela 13, foi mostrado estatisticamente que os contornos da imagem ouro e da imagem segmentada, em sua maioria são considerados equivalentes. No entanto, para 37% dos casos não foi possível obter uma segmentação estatisticamente equivalente, como pôde ser visto que nos casos em que a hipótese nula foi rejeitada.

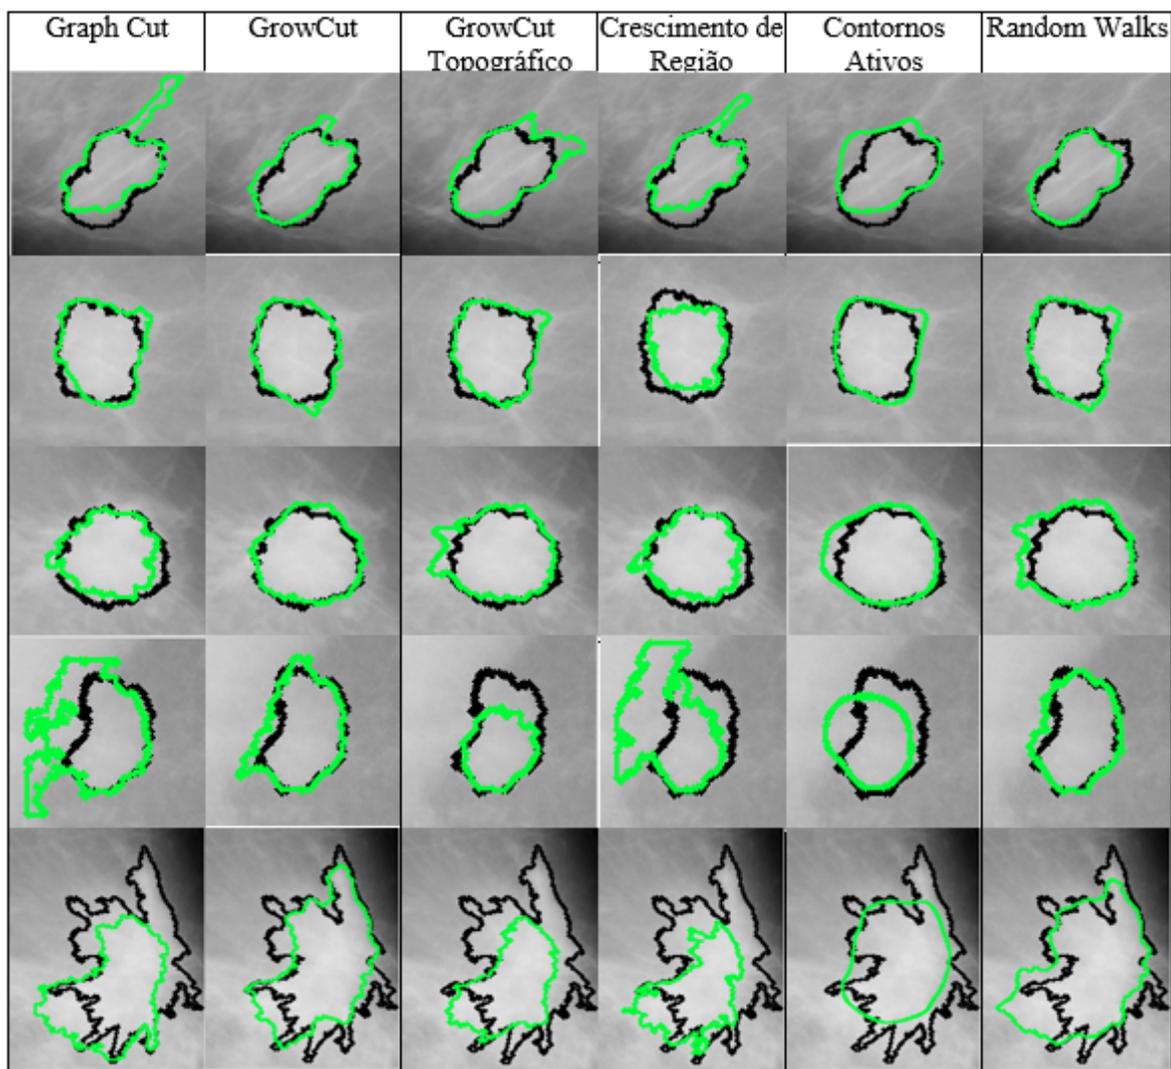
A dificuldade em se utilizar uma técnica híbrida está no fato das técnicas baseadas em semente dependerem muito no posicionamento correto de sementes iniciais. Essa característica é compreensível, visto que a localização das sementes geralmente é feita por um especialista. No entanto, para se utilizar uma abordagem híbrida é necessário tornar o método GrowCut mais flexível quanto a localização das sementes, pois a geração automática de sementes é sujeita a falhas e imprecisões quanto ao posicionamento de sementes.

### 5.2.5 Comparação do GrowCut com Técnicas Supervisionadas

Um estudo comparativo foi realizado entre o GrowCut, TGC, Crescimento de Região, Random Walks, Contornos Ativos e Graph Cut. Essa análise foi realizada para o mesmo conjunto de imagens dos experimentos anteriores, observando a qualidade da segmentação final de cada técnica e a imagem ouro fornecida.

A Tabela 14 mostra a comparação da segmentação de alguns casos, para cada técnica. Cada coluna da Tabela 14 mostra os resultados da segmentação de cada técnica para a região de interesse selecionada, e cada linha corresponde a uma imagem diferente do Mini-MIAS. Em cada célula, o contorno preto na imagem representa o contorno da imagem ouro, enquanto que o contorno verde corresponde à segmentação final da técnica.

**Tabela 14** – Comparação da segmentação final entre Graph Cut, GrowCut, GrowCut Topográfico, Crescimento de Região, Contornos Ativos e Random Walks, para as imagens mdb202, mdb025, mdb012, mdb015 e mdb134.



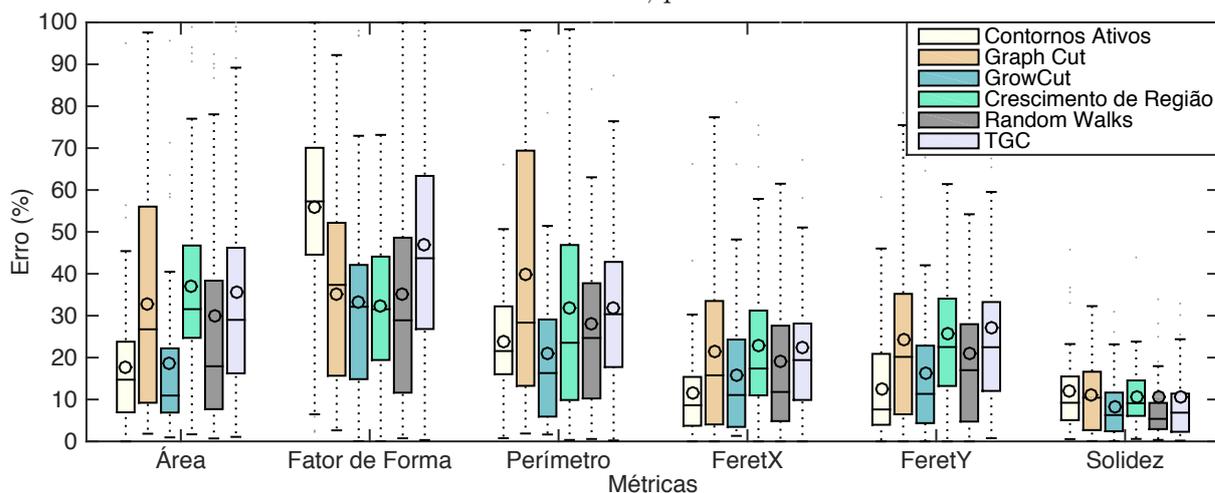
Fonte: do autor.

Na Tabela 14 foi possível observar que para a maioria dos casos todas as técnicas obtiveram uma boa precisão na segmentação. No entanto, em mamogramas onde as lesões são espiculadas ou apresentam baixa densidade, o que representam os casos mais difíceis, algumas técnicas não obtiveram boas segmentações.

Em geral, o GrowCut e o Random Walks obtiveram melhores resultados, principalmente nos casos de imagens mais difíceis. A técnica GrowCut, por sua vez, requer menor seleção de sementes do que o Random Walks, o que reduz o esforço de interação com o usuário, mantendo a qualidade da segmentação. Em termos de desempenho, o Random Walks é mais rápido do que o GrowCut, porém o GrowCut é ainda bastante rápido para a segmentação das regiões de interesse testadas. O tempo médio exato de segmentação para cada algoritmo não foi abordado nessa etapa do trabalho. O GrowCut Topográfico, apesar de ter segmentado bem a maioria das imagens, obteve dificuldade em encontrar um contorno final de segmentação em alguns casos de imagens mais difíceis. No entanto, o TGC, enquanto técnica semi supervisionada, obteve em geral uma segmentação próxima à imagem ouro, além do benefício de não requerer nenhuma interação com o usuário para seleção de sementes.

Um último estudo foi realizado observando as métricas descritas anteriormente. As métricas foram aplicadas para cada técnica e obtido um erro médio relativo da segmentação. O erro relativo é estimado para as métricas de Área, Perímetro, Distância de *Feret* e Solidez, para todas as técnicas e imagens analisadas. Quanto mais baixo o erro relativo melhor a qualidade da segmentação. A Figura 50 mostra o erro relativo, em porcentagem, com uma análise de *boxplot* para cada métrica. Quanto menor for o comprimento e mais embaixo estiver o *boxplot*, melhor o resultado.

**Figura 50** – *Boxplot* dos erros de segmentação de Contornos Ativos, Graph Cut, Grow Cut, Crescimento de Região (CR), Random Walks e TGC, para as métricas de Área, Fator de Forma, Perímetro, FeretX, FeretY e Solidez, para a base Mini-MIAS.



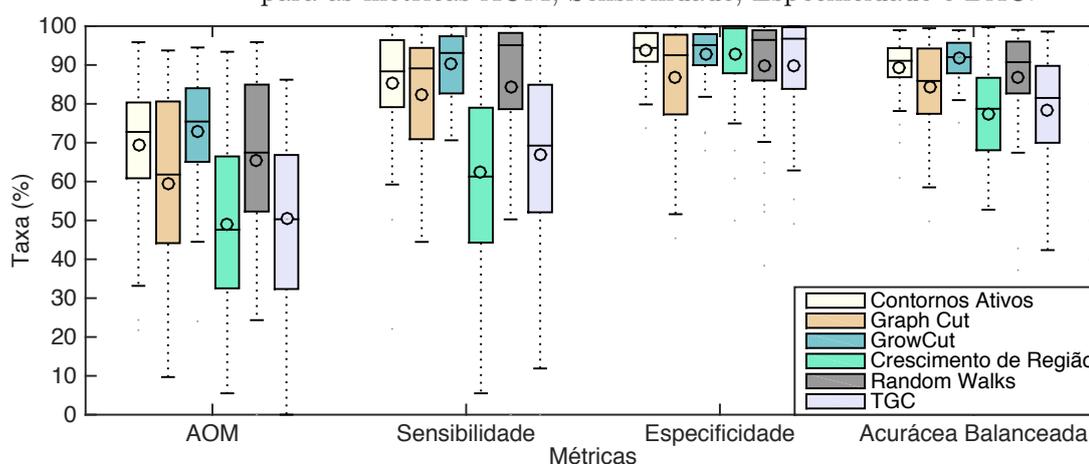
Fonte: do autor.

De acordo com a Figura 50, o GrowCut obteve o menor erro médio de segmentação e com menor intervalo entre valores mínimos e máximo, quando comparado com as outras técnicas. A técnica de Contornos Ativos, apesar de apresentar erro de Área, *FeretX* e

*FeretY* próximos de zero, apresentou erro acima de 50% para a métrica de Fator de Forma. Isso aconteceu porque a técnica de Contornos Ativos não foi capaz de segmentar bem bordas espiculadas. Portanto, apesar de obter uma área próxima da imagem ouro, o formato da segmentação obtida foi considerado diferente por não apresentar bordas espiculadas, para a maioria dos casos. Todas as técnicas obtiveram erro mínimo próximo a zero, o que correspondem a imagens onde a lesão é relativamente fácil de segmentar. Por outro lado, os erros máximos indicam que algumas técnicas, tais como TGC e Graph Cut, não conseguiram obter bons resultados para as métricas de área e perímetro, para algumas imagens com bordas complexas. Para essas métricas, o GrowCut obteve menor erro médio, o que representa uma melhor segmentação, em geral, quando comparado com as outras técnicas. O GrowCut Topográfico, apesar de não apresentar os menores erros médios, ainda pode ser considerada uma boa técnica de segmentação para a maioria das imagens analisadas, onde o teste de hipótese realizado para a segmentação obtida foi próximo foi equivalente à imagem ouro. Pôde-se observar que o TGC pode ser bem aplicado quando a borda da lesão é bem definida e a lesão não é muito espiculado. No entanto, em casos mais difíceis a segmentação do TGC tem um erro maior. Contudo, o TGC obteve bons resultados em média, podendo ser melhorado em trabalhos futuros através de ajustes na seleção inicial das sementes.

A Figura 51 mostra os resultados obtidos para as métricas AOM, Sensibilidade, Especificidade e Acurácia Balanceada. Para essas métricas, quanto maior o valor, melhor o resultado.

**Figura 51** – *Boxplot* dos erros de segmentação de Contornos Ativos, Graph Cut, Grow Cut, Crescimento de Região (CR), Random Walks e TGC, para as métricas AOM, Sensibilidade, Especificidade e BAC.



Fonte: do autor.

De acordo com a Figura 51, o GrowCut obteve melhores valores para as métricas AOM, Sensibilidade, Especificidade e BAC, o que indica que o GrowCut obteve média de

valores mais altos, com menor intervalo, indicando uma melhor segmentação, mesmo para imagens com bordas irregulares. A técnica de Contornos Ativos e Random Walks também obtiveram bons resultados para essas métricas. No entanto, como descrito anteriormente, as métricas devem ser analisadas em conjunto, e apesar da métrica AOM estar indicar uma proximidade com a imagem ouro, o formato da região segmentada pode ser diferente, conforme demonstrado anteriormente pela métrica de Fator de Forma.

Por fim, foi realizado o teste de hipótese de Wilcoxon aplicado para cada par de imagem ouro e imagem segmentada, comparando a distribuição do SSP. O teste foi aplicado ao conjunto inteiro de imagens, usando índice de confiança de 0,05. A hipótese nula usada foi que cada par de amostras é igual. Os resultados, incluindo *p-value* médio, valor mínimo, máximo e desvio padrão são mostrados na Tabela 15. Ter a hipótese nula rejeitada significa que a distribuição do SSP da imagem segmentada e da imagem ouro são diferentes. Isso significa que o formato da imagem segmentada e da imagem ouro possuem diferença significativa. Na Tabela 15, possuir um maior *p-value* médio e menor número de hipóteses nulas rejeitadas representa uma melhor qualidade na segmentação.

**Tabela 15** – Teste Ranqueado de Wilcoxon aplicado para imagens segmentadas e imagens ouro, comparado a distribuição da métrica *Slope Spectrum Pattern*, para todas as técnicas analisadas.

Técnicas	<i>p-value</i> médio	Desvio Padrão	#Hipóteses Nulas Rejeitadas	#Hipóteses Nulas Não Rejeitadas
Contornos Ativos	0,0775	0,1746	44	13
GraphCut	0,3370	0,3465	17	40
GrowCut	0,3593	0,3193	17	40
Crescimento de Região	0,1267	0,2435	43	14
RW	0,3455	0,3440	20	37
TGC	0,2779	0,2955	21	36

A partir da Tabela 15, observa-se que as técnicas GraphCut e GrowCut obtiveram resultados similares, com menor número de hipóteses nula rejeitadas, o que significa que poucas imagens segmentadas foram consideradas diferentes da imagem ouro. A técnica Contornos Ativos obteve o maior número de hipóteses rejeitadas, devido a sua dificuldade em lidar com bordas espiculadas. A métrica SSP reflete os resultados obtidos pela métrica Fator de Forma, que analisa o formato da segmentação. Como o formato da lesão é um aspecto importante para a obtenção de um diagnóstico preciso, é importante que a imagem segmentada tenha um formato próximo da região real da lesão. Para essa métrica, o GrowCut mostrou-se competitivo e eficiente para segmentação de lesões.

### 5.2.6 Considerações da Análise de Segmentação do GrowCut

Foi realizado um estudo inicial da aplicação da técnica GrowCut para segmentação de lesões em imagens de mamografia digital. Resultados dessa aplicação mostraram que o

GrowCut é uma técnica adequada para realizar segmentação de lesões, obtendo qualidade de resultado de segmentação próximos aos encontrados pelas técnicas do estado da arte. Técnicas como GraphCut e RandomWalks, também apresentaram bons resultados, porém requerem ajustes de parâmetros para obter um desempenho ótimo ao problema, o que requer a adição de conhecimento especialista.

Além disso, foi proposta uma extensão do algoritmo GrowCut, para torná-lo semi-supervisionado. Essa extensão envolveu o uso de limar multinível para selecionar as sementes iniciais. No entanto, o modelo semi-automático não obteve resultados tão bons como as técnicas supervisionadas do estado da arte. Isso se deve ao fato da necessidade de tornar o posicionamento das sementes iniciais mais flexível.

Na seção a seguir é descrito o algoritmo proposto, que utiliza o algoritmo GrowCut como base para desenvolver um modelo semi-supervisionado, com mais robustez quanto ao posicionamento de sementes e menor esforço especialista.

### 5.3 DESCRIÇÃO DO ALGORITMO PROPOSTO

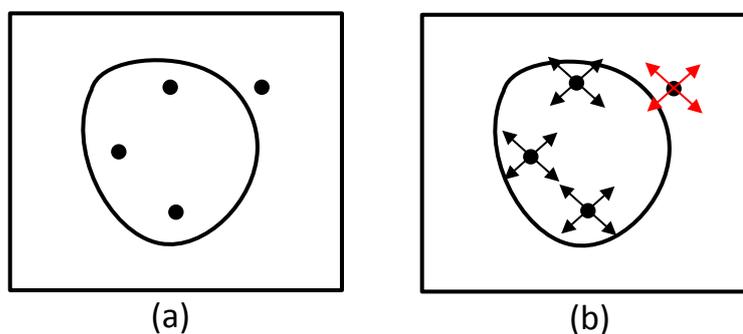
No GrowCut, assim como na maioria das técnicas baseadas em sementes, a qualidade da segmentação depende diretamente na posição inicial das sementes. Portanto, ela depende do conhecimento do usuário para selecionar corretamente as sementes próximo à borda do objeto a ser segmentado. No caso de algumas sementes serem inicializadas com rótulo incorreto, o algoritmo pode realizar uma segmentação indesejada e imprecisa. O impacto que isso causa é a dificuldade de se utilizar um método automático de geração de sementes, retirando o requerimento do especialista, pois a geração de sementes pode conter imprecisões que impactam na qualidade final da segmentação. Além disso, mesmo em um método supervisionado, o posicionamento das marcações iniciais está sujeito ao erro humano e o resultado da segmentação pode variar dependendo do conhecimento especialista. Um dos objetivos do algoritmo proposto é tornar o posicionamento das sementes mais flexível e com menor impacto na segmentação final. Isso, além de reduzir o conhecimento especialista necessário, permitirá uma melhor qualidade na geração de um modelo semi-supervisionado, utilizando geração automática de sementes, pois será mais robusto quanto ao posicionamento das mesmas.

Conforme descrito no capítulo 1, o processo de posicionamento de sementes é naturalmente impreciso. No entanto, técnicas baseadas em sementes se baseiam na premissa de que a marcação inicial das sementes está correto e inicializam o processo de segmentação a partir dessa informação. O algoritmo GrowCut, por exemplo, que atribui para cada célula uma força associada à capacidade de dominar células vizinhas, atribui células com força máxima todas as marcações realizadas pelo usuário. As células com força máxima são incapazes de ter seu rótulo inicial alterado e tem alta capacidade de espalhar o seu rótulo para células vizinhas. Desta forma, caso uma semente com rótulo de lesão seja

posicionada em uma região sem lesão, a segmentação em volta da semente posicionada incorretamente será segmentada também de forma incorreta.

Com base nas hipóteses descritas na seção 1.2, esse trabalho se propõe a amenizar esse problema através da inserção de um modelo de incerteza no processo de segmentação do GrowCut. Esse modelo se baseia no conceito de que as sementes iniciais podem fornecer informação de uma região de probabilidade de existência de lesão. Fornecendo essa probabilidade, a localização das sementes individualmente não precisa ser considerada como verdade absoluta da existência ou não da lesão. Ou seja, o modelo passa a se basear na informação sobre a região aproximada, que é o que o especialista tem maior conhecimento, e não sobre o posicionamento individual das sementes. Com isso será possível ter uma maior variação no posicionamento das sementes, pois o que é levado em conta é a informação global do posicionamento das sementes, para mapear uma região de incerteza, ao invés da informação local. A Figura 52 ilustra o conceito de segmentação utilizado no GrowCut e na maioria dos algoritmos de segmentação baseados em semente.

**Figura 52** – Conceito de propagação de rótulos utilizado no GrowCut, baseado em informação local do posicionamento das sementes: (a) Sementes iniciais fornecidas pelo usuário; (b) propagação de rótulo a partir das sementes informadas pelo usuário.



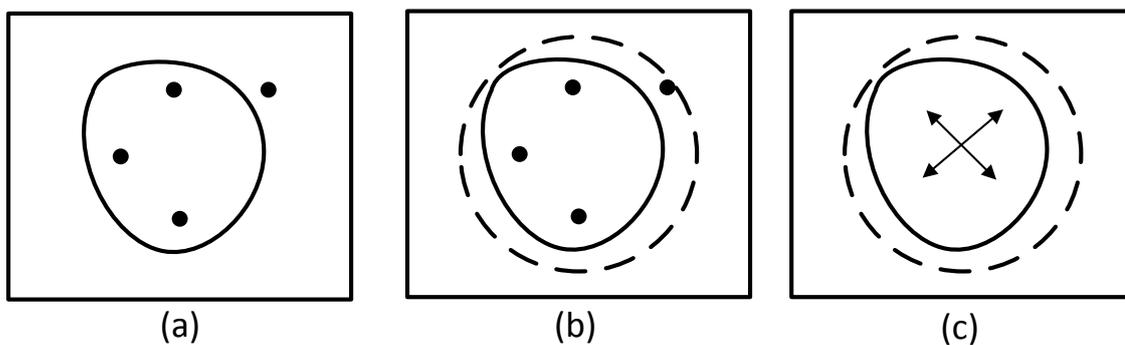
Fonte: do autor.

A Figura 52 (a) ilustra uma região de interesse contendo uma região de lesão, em formato aproximado de uma elipse. Os pontos pretos representam sementes marcadas pelo especialista, com rótulo de lesão. A Figura 52 (b) ilustra como é o conceito de propagação rótulos utilizado no GrowCut. As setas saindo dos pontos em preto representam a informação sendo propagada pela imagem. Na abordagem utilizada pelo GrowCut, as sementes iniciais são fontes confiáveis de informação e realizam a propagação do rótulo da semente baseado em informação de contraste e força entre as células. A seta em vermelho representa uma propagação incorreta, devido ao mal posicionamento de uma semente fora considerada com rótulo de lesão, mas fora da região de lesão. Uma marcação desse tipo levaria à uma segmentação indesejada.

A Figura 53 ilustra o conceito de propagação de rótulo utilizado no algoritmo proposto. A Figura 53 (a) representa as sementes iniciais fornecidas pelo usuário, consideradas

como pertencentes à região de lesão. A ideia é que a partir das sementes iniciais se extraia informações sobre a probabilidade de haver lesão na região onde as sementes estão. Embora algumas sementes possam estar localizadas incorretamente, a informação aproximada da probabilidade de ocorrência de lesão pode ser utilizada para guiar a propagação dos rótulos da imagem. A Figura 53 (b) representa em linha pontilhada uma região aproximada em que há maior probabilidade de ocorrência da lesão, baseado em informação da localização das sementes. A Figura 53 (c) mostra a propagação sendo realizada a partir do centro dessa região. Como a propagação é realizada a partir do centro, ela mais flexível à variação do posicionamento inicial das sementes.

**Figura 53** – Conceito de propagação de rótulos utilizado no algoritmo proposto, baseado em informação global da localização das sementes: (a) Sementes iniciais fornecidas pelo usuário; (b) estimativa de uma região de probabilidade de ocorrência de lesão; (c) propagação de rótulos a partir do centro da região estimada.



Fonte: do autor.

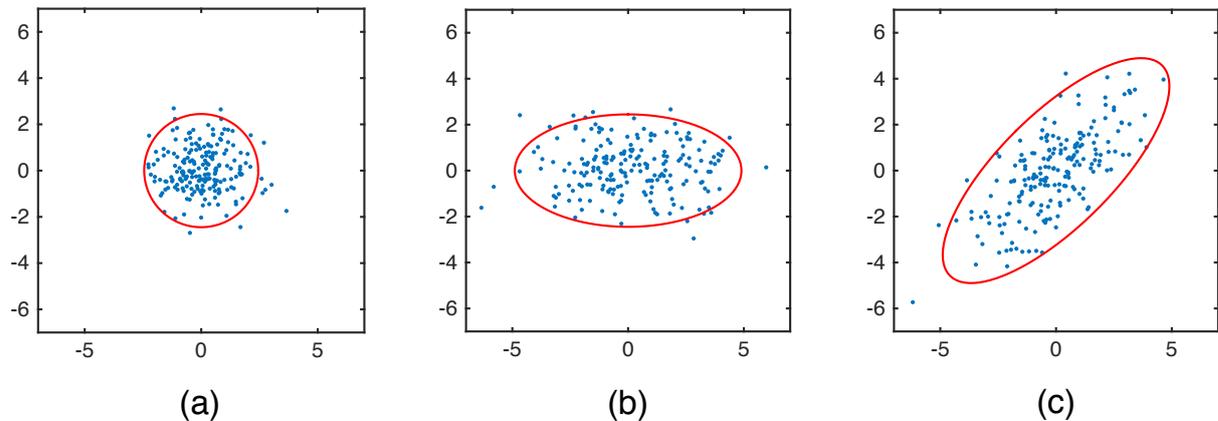
Uma das formas de adicionar incerteza ao processo de seleção de sementes é mapear a região próxima à marcação inicial das sementes como uma região de pertinência baseado na distribuição dos pontos. Uma função que faz esse mapeamento de forma simples é através do uso da função Gaussiana (LIFSHITS, 2013). A função Gaussiana é uma função de densidade de probabilidade de uma distribuição normal e que pode ser representada, baseada em parâmetros de média e variância. A função de pertinência *fuzzy* Gaussiana bidimensional pode ser representada pela Equação 5.2 (ALPAYDIN, 2014).

$$f(x, y) = \exp\left(-\frac{(x - \mu_x)^2}{2s_x^2}\right) \exp\left(-\frac{(y - \mu_y)^2}{2s_y^2}\right), \quad (5.2)$$

onde as variáveis  $x$  e  $y$ , que são as coordenadas e os parâmetros  $\mu_x$ ,  $s_x$ ,  $\mu_y$  e  $s_y$  são a média e desvio padrão da distribuição das variáveis  $x$  e  $y$ , respectivamente.

A Figura 54 mostra a região gaussiana encontrada a partir de um conjunto de exemplos aleatórios bidimensionais, seguindo uma distribuição normal, mostrando três exemplos através da Figura 54 (a), Figura 54 (b) e Figura 54 (c), respectivamente.

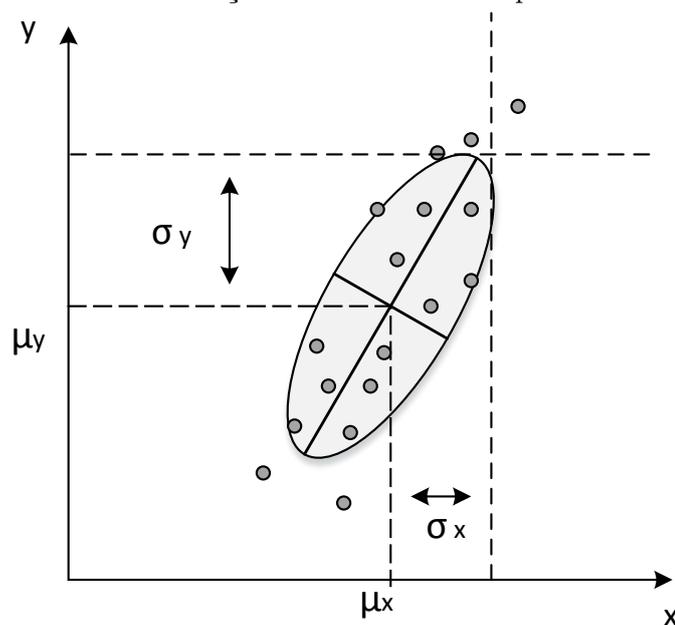
**Figura 54** – Região Gaussiana encontrada a partir de um conjunto de exemplos aleatórios bidimensionais com distribuição normal.



Fonte: do autor.

Os pontos em azul na Figura 54 representam variáveis bidimensionais geradas aleatoriamente. A região em vermelho indica a região Gaussiana encontrada com maior probabilidade de encontrar um dado pertencente àquela amostra. O formato mais circular ou elipsóide varia conforme as informações de média e desvio padrão da distribuição. A inclinação da região encontrada é baseada no valor do desvio padrão em cada uma das dimensões. A Figura 55 mostra a influência do desvio padrão na forma da região. O alongamento vertical e horizontal da região Gaussiana é baseada no desvio padrão dos dados, em cada uma das dimensões (FRIENDLY et al., 2013).

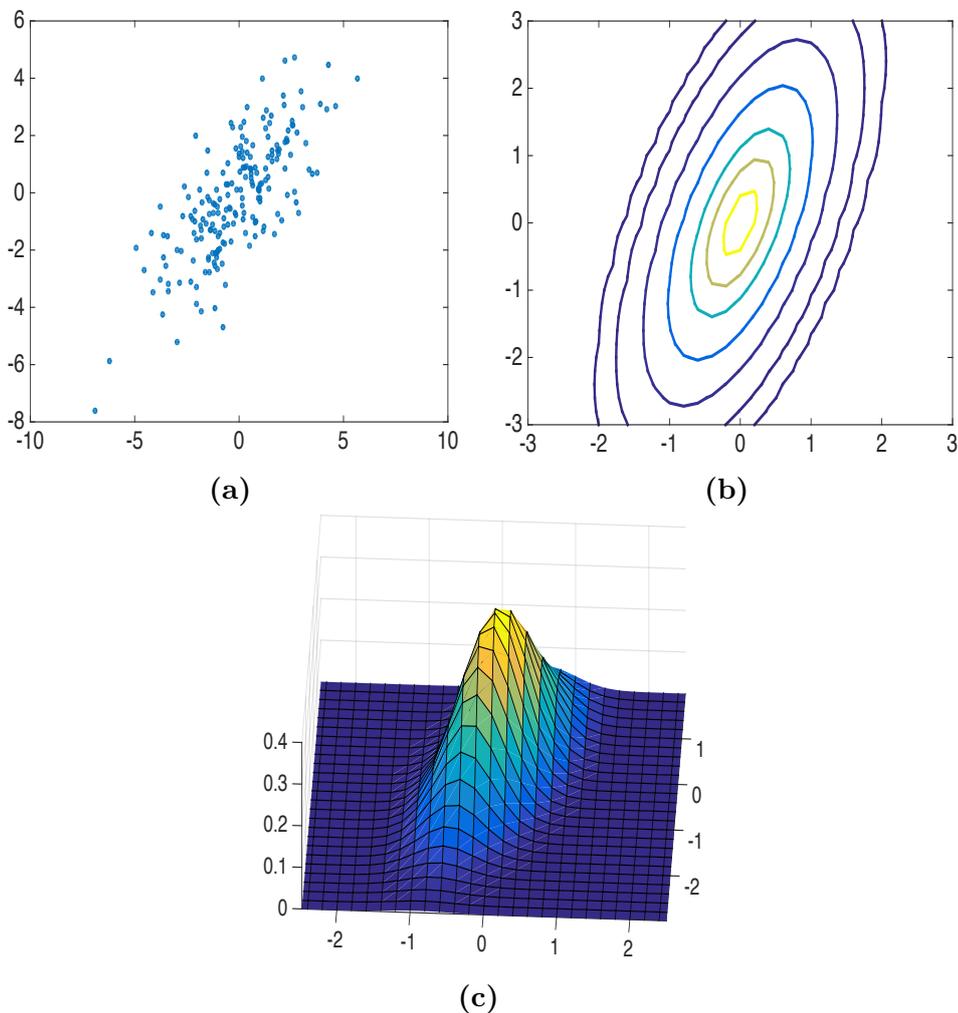
**Figura 55** – Tamanho, localização e inclinação da região Gaussiana baseada em informação de média e desvio padrão dos dados.



Fonte: do autor.

Quanto mais perto do centro do centro de massa da região Gaussiana, maior a probabilidade de um dado pertencer à distribuição. A Figura 56 (a) mostra uma distribuição aleatória de pontos e a Figura 56 (b) mostra diferentes níveis de probabilidade dentro da região Gaussiana. Quanto mais interna a região, maior a probabilidade de um dado pertencer à amostra. O mesmo conceito pode ser aplicado à seleção de sementes, ou seja, a partir da determinação da região Gaussiana, quanto mais próximo do centro de massa da região, maior certeza da região de lesão. A Figura 56 (c) mostra a região Gaussiana em três dimensões.

**Figura 56** – (a) Distribuição normal de pontos; (b) Regiões de probabilidade de pertinência à região Gaussiana ; (c) Região Gaussiana em três dimensões.



Fonte: do autor.

As sementes utilizadas em um método de segmentação supervisionada podem ser representadas como dados bidimensionais com valores informando a posição da semente no eixo  $x$  e  $y$ . Desta forma é possível representar o conjunto de sementes, quer seja gerado de forma manual ou automática, através de uma região Gaussiana.

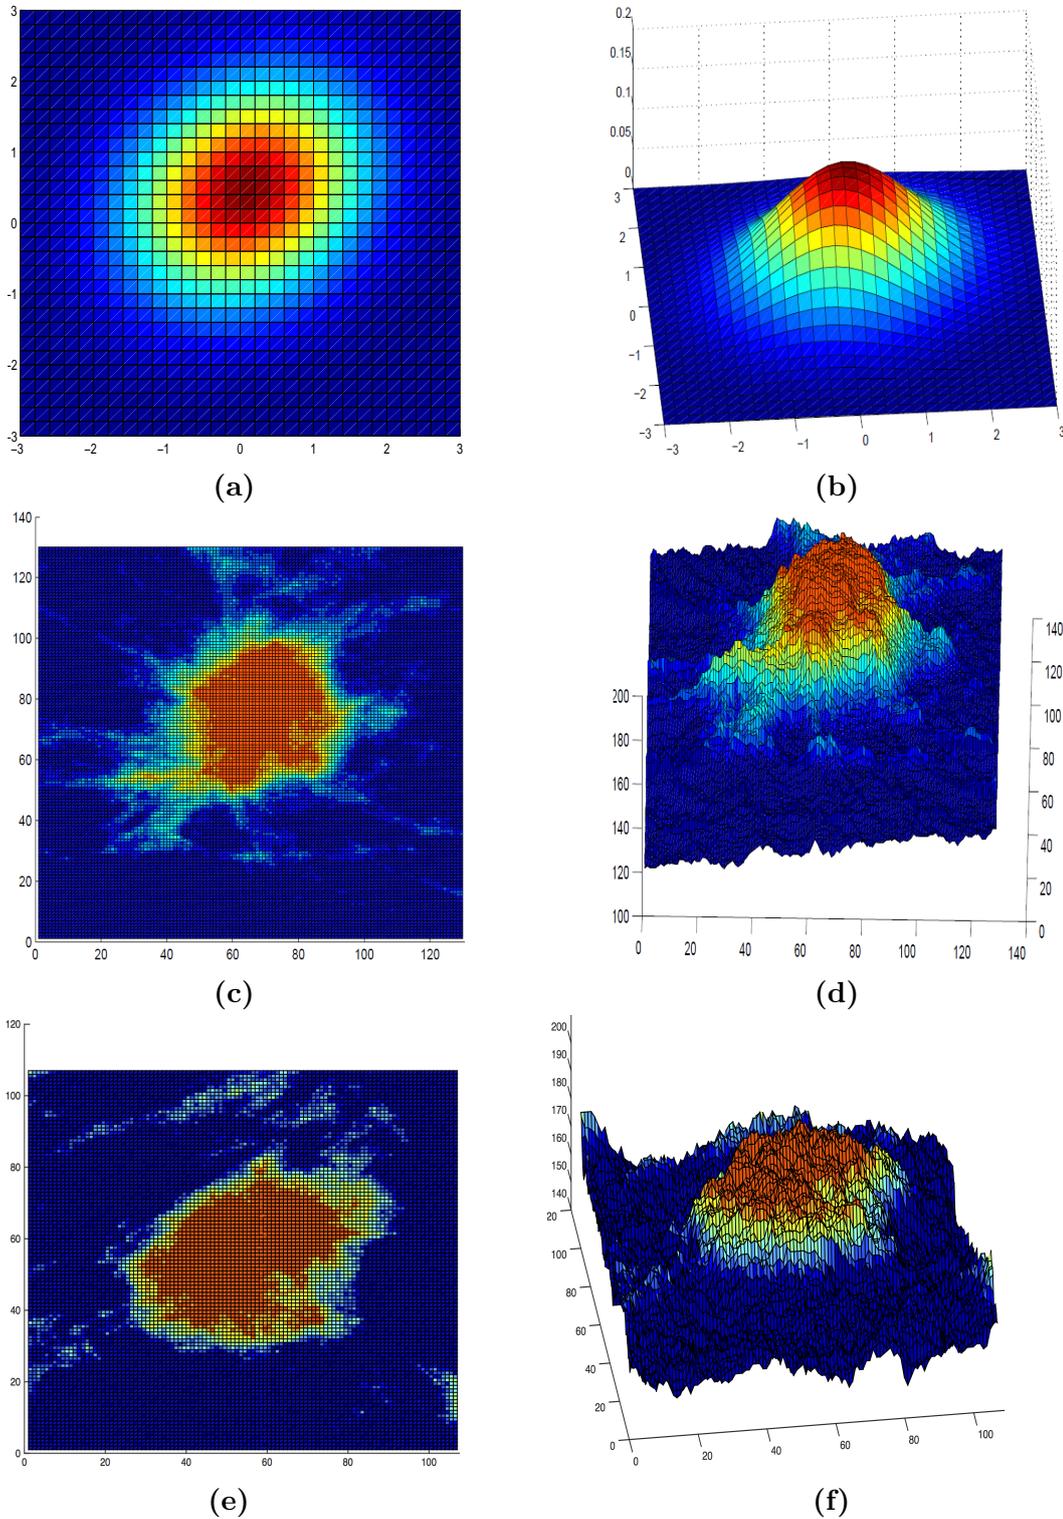
As Figuras 58 (a) e 58 (b) mostram um exemplo de região Gaussiana, em duas e três dimensões, respectivamente, onde as regiões em vermelho indicam maior frequência dos dados, mas também pode ser interpretado como uma região de maior chance de um dado estar presente.

A Figura 58 (c) e Figura 58 (e) mostram imagens de lesão de mamografia digital mapeada em níveis de intensidade. As regiões mais vermelhas representam regiões com *pixels* de maior intensidade e as azuis de menor intensidade. A Figura 58 (d) e Figura 58 (f) mostra imagens da lesão em três dimensões. Como pode ser observado, a região de lesão tem um comportamento parecido com o da região gaussiana. Desta forma, a região de lesão descrito por uma imagem de mamografia digital pode ser representada por uma função gaussiana, de forma que a função seja uma aproximação da região em que a lesão se encontra. O mesmo pode ser observado em outras imagens de lesão e em lesões espiculadas, circunscritas ou indistintas, pois o interesse inicial na representação pela função gaussiana é na região em que a lesão se encontra, e não na delimitação exata do contorno. Baseado na representação gaussiana, a mesma pode ser representada por uma função de pertinência de presença de lesão. Desta forma, pode-se definir uma região *fuzzy*-gaussiana de pertinência de um *pixel* à região de lesão. É utilizado lógica *fuzzy* porque ela fornece um grau de pertinência de pertencer a cada classe do problema. Como o problema de encontrar a região de lesão envolve um nível de incerteza quanto a localização, é adequado utilizar uma representação que forneça um grau de pertinência da região pertencer a cada classe. Essa representação é útil para guiar um modelo baseado em sementes, pois ela determina um modelo não apenas baseado em sementes iniciais, mas sim baseado em uma região de pertinência. Se a região de lesão pode ser mapeada por uma função de pertinência *fuzzy*-gaussiana, então as sementes localizadas dentro da região de lesão também podem. Desta forma, a localização inicial pode fornecer um grau de pertinência do *pixel* à região lesão ou não-lesão, o que pode guiar a segmentação do algoritmo. O modelo proposto utiliza essa representação.

No modelo proposto, a localização inicial das sementes é o suficiente para a estimativa da função *fuzzy*-gaussiana. Uma vez que a estimativa do modelo se baseia nos parâmetros de média, desvio padrão e centro de massa, algumas amostras são o suficiente para a estimativa da região. A Figura 60 mostra uma ilustração de estimativa da região *fuzzy*-gaussiana baseada nas sementes iniciais. A Figura 60 (a) mostra uma imagem contendo lesão, a Figura 60 (b) mostra um exemplo de seleção inicial de sementes, e a Figura 60 (c) mostra a região *fuzzy*-gaussiana estimada, onde há maior grau de pertinência de um *pixel* pertencer à região de lesão.

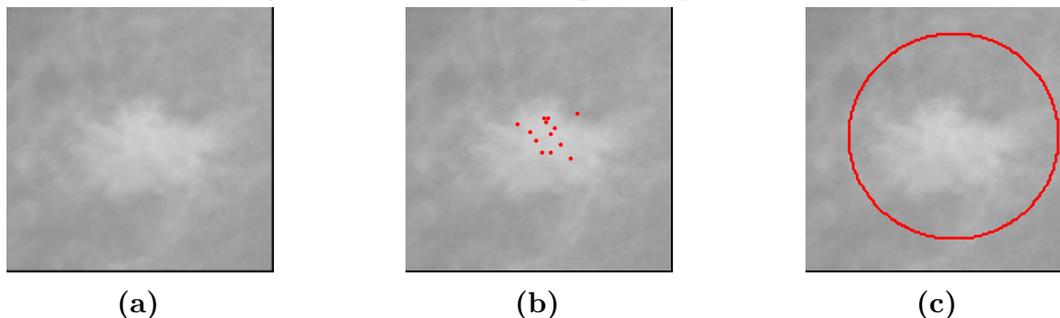
Com a modificação proposta do algoritmo GrowCut, visamos auxiliar o especialista na inicialização sobre o contorno do objeto de interesse através da redução do esforço da seleção de sementes. Além disso, o modelo proposto se propõe a ser tolerante a

**Figura 58** – (a) Região Gaussiana em duas dimensões; (b) Níveis de intensidade de uma lesão, em duas dimensões; (c) Região Gaussiana em três dimensões; (d) Níveis de intensidade de uma lesão, em três dimensões; (e) Níveis de intensidade d em duas dimensões; (f) Níveis de intensidade em três dimensões.



Fonte: do autor.

**Figura 60** – (a) Imagem original contendo lesão; (b) Sementes iniciais (c) Região *Fuzzy-Gaussiana* com maior grau de pertinência à classe de lesão.



Fonte: do autor.

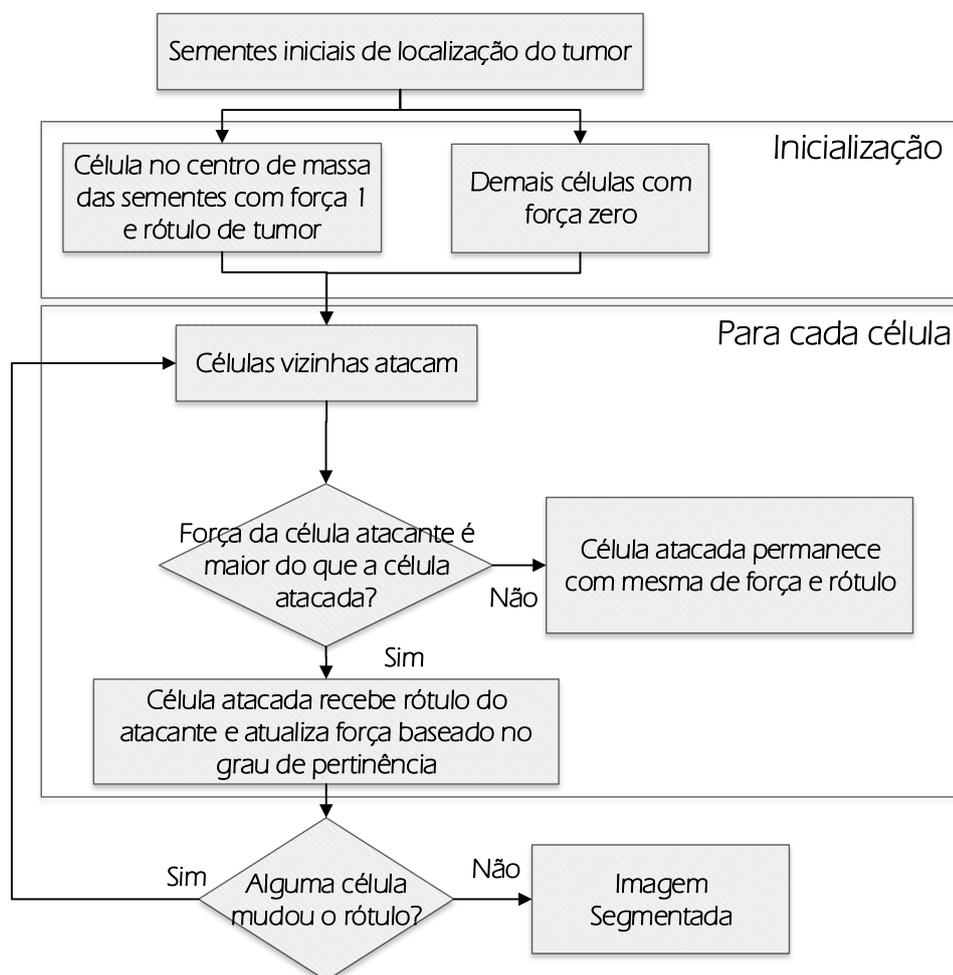
falhas, permitindo-o se recuperar da seleção incorreta de sementes. Sendo assim, o modelo proposto realiza uma modificação nas equações do GrowCut, reformulando seu processo de segmentação para utilizar um modelo *fuzzy*. Esse modelo é utilizado porque a região de fronteira da lesão é incerta, e diferente dos modelos do estado da arte, ele torna o processo de seleção de sementes mais flexível, pois uma semente não é tida como verdade absoluta. Adicionalmente, é utilizada uma metodologia de seleção automática de sementes, que juntamente com o modelo proposto apresentam um novo método semi-automático de segmentação.

A principal diferença do método proposto para os métodos baseados em sementes é que as sementes iniciais não são consideradas como verdades absolutas, mas sim como estimativas de localização da lesão. Isso permite a flexibilidade da escolha das sementes, possibilitando que algumas sementes da classe de lesão possam estar localizadas fora da região de lesão. O importante, para a técnica proposta, é que o centro de massa das sementes esteja dentro da lesão, caso contrário a segmentação não será bem sucedida. Desta forma, a técnica proposta mostra-se favorável à utilização de um método não-supervisionado de seleção de sementes, uma vez que algumas sementes podem estar em localização incorreta.

Um dos aspectos mais importantes do método proposto é que não é necessário a utilização de sementes da classe de fundo, como os métodos baseados em sementes fazem. Isso é possível porque as sementes não são utilizadas como pontos de crescimento de região, mas sim como entrada para a estimativa da região *fuzzy-gaussiana*. A técnica conduz a propagação dos rótulos baseado na região *fuzzy-gaussiana*, e a mesma é obtida apenas com as sementes da classe de lesão. O impacto disso é que o esforço de seleção de sementes é reduzido pela metade, e, portanto, o conhecimento necessário para realizar a segmentação. O fluxograma do algoritmo proposto é mostrado na Figura 62.

Como é mostrado na Figura 62, o algoritmo recebe como entrada as sementes iniciais, que podem ser selecionadas pelo usuário ou por algum algoritmo não supervisionado. Uma vez obtidas as sementes, é feito o processo de inicialização de rótulos e forças das células,

Figura 62 – Fluxograma do Algoritmo Proposto.



Fonte: do autor.

que diferencia-se do modelo do GrowCut.

Uma das limitações do GrowCut clássico é que todas as sementes iniciais selecionadas pelo usuário têm força máxima, atribuindo um peso grande para sementes com rótulos errados. Diferente do GrowCut, o modelo proposto baseia-se apenas na seleção de sementes de uma classe: a do objeto de interesse. Descartamos a seleção das sementes da classe de fundo porque a partir das sementes da classe de objeto pode-se estimar uma região de fronteira separando objeto e fundo. No entanto, ao invés de se atribuir todas as células rotuladas com força máxima, todas as células são inicializadas com força zero, exceto a célula correspondente ao centro de massa das sementes de entrada. Isso permite flexibilidade na localização das sementes, reduzindo a necessidade de conhecimento sobre a região da lesão. Desta forma, atribui-se força máxima à célula do centro de massa porque assumimos que ela possui maior chance de estar com o rótulo correto. A inicialização é

realizada conforme a Equação 5.3.

$$\forall p \in P, l_p = 0, \Theta_p = 0, l_{cm} = l_{ob}, \Theta_{cm} = 1; \quad (5.3)$$

onde  $p$  é uma célula no espaço  $P$  de células, e  $l_p$  e  $\Theta_p$  são o rótulo e a força da célula  $p$ , respectivamente. O valor  $l_p = 0$  representa a célula  $p$  com rótulo indefinido. O rótulo e força da célula que corresponde ao centro de massa é representado por  $l_{cm}$  e  $\Theta_{cm}$ , respectivamente.

Após a etapa de inicialização é realizada a etapa de atualização dos rótulos das células, onde cada célula é atacada pelas células vizinhas. Caso alguma célula atacante possua força maior do que a célula atacada, a célula atacada recebe o rótulo da célula atacante. O processo se repete até que nenhuma célula possua mais seu rótulo alterado. O modelo proposto realiza uma modificação na regra de atualização das células do GrowCut, de forma que o ataque de cada célula seja baseado na região modelada por uma função *fuzzy*-gaussiana. A força das células do modelo serão igual a 1 caso o grau de pertinência da mesma pertencer ao fundo da imagem seja maior do que a de pertencer ao objeto. Caso contrário, a força do modelo assume a força atual da célula. O algoritmo de atualização é mostrado no Pseudocódigo 3, onde  $\Theta_{Mp}^t$  e  $\Theta_{Mq}^t$  são forças a força do modelo para as células  $p$  e  $q$ , respectivamente, sendo representados pelas Equações 5.4 a 5.6.

---

**Pseudocódigo 3** Regra de Evolução Modificada do GrowCut
 

---

```

1: procedure MODIFIEDGROWCUT( $P, l$ )
2:    $l_{cm} = l_{obj}$ 
3:    $\Theta_{cm} = 1$ 
4:   for all  $p \in P$  do
5:      $l_p^{t+1} \leftarrow l_p^t$ 
6:      $\Theta_p^{t+1} \leftarrow \Theta_p^t$ 
7:     Calcula  $\Theta_{Mp}^t$ 
8:     for all  $q \in N(p)$  do
9:       Calcula  $\Theta_{Mq}^t$ 
10:      if  $g(\|\vec{C}_p - \vec{C}_q\|_2) \cdot \Theta_{Mq}^t > \Theta_{Mp}^t$  then
11:        Calcula  $l_{M,p,q}^t$ 
12:         $l_p^{t+1} \leftarrow l_{M,p,q}^t$ 
13:         $\Theta_p^{t+1} \leftarrow g(\|\vec{C}_p - \vec{C}_q\|_2) \cdot \Theta_{Mq}^t$ 
14:      end if
15:    end for
16:  end for
17:  return  $l$ 
18: end procedure

```

---

$$\Theta_{M,i} = \begin{cases} 1, & \mu_{\text{Bkg}}(i) > \mu_{\text{Obj}}(i) \\ \Theta_i, & \mu_{\text{Bkg}}(i) \leq \mu_{\text{Obj}}(i) \end{cases}, \quad (5.4)$$

$$\mu_{\text{Bkg}}(i) = 1 - \mu_{\text{Obj}}(i), \quad (5.5)$$

$$\mu_{\text{Obj}}(i) = \exp\left(-\frac{(x_i - x_m)^2}{2\alpha_x s_x^2}\right) \exp\left(-\frac{(y_i - y_m)^2}{2\alpha_y s_y^2}\right), \quad (5.6)$$

onde  $\mu_{\text{Bkg}}(i)$  é o grau de pertinência *fuzzy* associado à incerteza da  $i$ -ésima célula pertencer ao fundo da imagem, enquanto  $\mu_{\text{Obj}}(i)$  é o grau de pertinência *fuzzy* associado à incerteza da  $i$ -ésima célula pertencer ao objeto de interesse. As funções de pertinência *fuzzy* são funções Gaussianas cujas variáveis  $x_i$  e  $y_i$  representam as coordenadas da célula na grade, enquanto que  $x_m$  e  $y_m$  representam o centro de massa, para os eixos horizontal e vertical, das sementes selecionadas inicialmente. As variáveis  $s_x$  e  $s_y$  representam o desvio padrão dos pontos iniciais, nos eixos horizontal e vertical, enquanto  $\alpha_x$  e  $\alpha_y$  são pesos de ajuste da região da função gaussiana. Os valores de  $\alpha_x$  e  $\alpha_y$  determinam o tamanho da região gaussiana, que pode ser ajustada de acordo com o problema de segmentação.

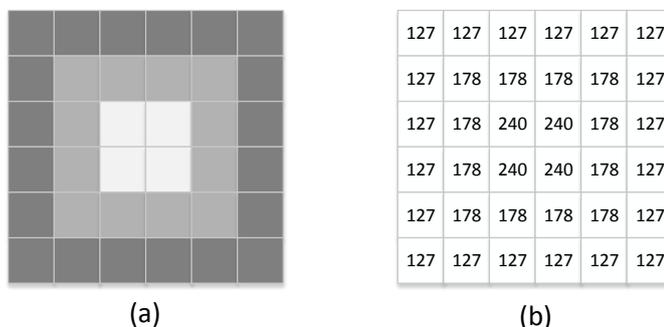
O rótulo de cada célula  $p$  também é atualizado seguindo o rótulo do modelo, representado por  $l_{Mq}^k$ , que atribui o rótulo de fundo, representado por  $l_{\text{Bkg}}$ , ou o rótulo da célula atacante  $q$ , conforme a Equação 5.7.

$$l_{M,p,q} = \begin{cases} l_{\text{Bkg}}, & \mu_{\text{Bkg}}(q) > \mu_{\text{Obj}}(q) \\ l_q, & \mu_{\text{Bkg}}(q) \leq \mu_{\text{Obj}}(q) \end{cases}. \quad (5.7)$$

A seguir é apresentado um exemplo numérico do funcionamento do *Fuzzy GrowCut*. O exemplo usa uma matriz 6x6, a qual representa uma imagem a ser segmentada. A Figura 63 (a) mostra a imagem exemplo, em tons de cinza, onde a região em branco representa a região da lesão que desejamos segmentar e os pixels em cinza representam a região de fundo. A Figura 63 (b) mostra a matriz de valores de intensidade de pixels correspondente da Figura 63 (a).

O primeiro passo do algoritmo é a seleção de sementes dentro da região de interesse. A Figura 64 (a) mostra a seleção de sementes, representada pelos círculos em vermelho. Como descrito anteriormente, a região em branco representa a região de lesão. Como a abordagem proposta é tolerante ao posicionamento incorreto de sementes, uma semente é posicionada fora da região de lesão, na Figura 64 (a), apenas para demonstração. Cada semente tem uma posição associada no eixo  $x$  e  $y$  da imagem. Em seguida é calculado o centro de massa baseado na posição das sementes, conforme mostrada na Figura 64 (b). Conforme descrito nas linhas 2 e 3 do Pseudocódigo 3, o rótulo do centro de massa é definido como da classe de objeto, ou seja, da região de lesão, e a força da célula correspondente ao *pixel* é definido como 1, como mostra a matriz de forças das células, representado na Figura 64 (c). A força do centro de massa é definido como 1, que é o valor máximo, pois é a região com maior grau de pertinência de haver a lesão, baseado na

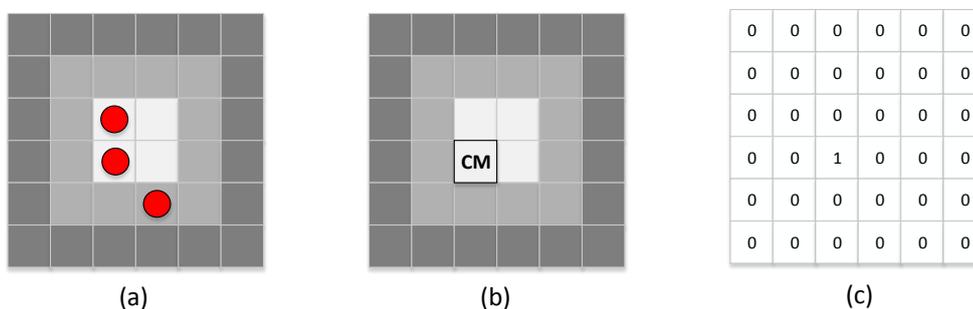
**Figura 63** – Imagem de entrada para o exemplo do algoritmo *Fuzzy GrowCut*: (a) Representação de uma imagem contendo uma região de lesão, em tons de cinza;(b) Matriz de valores intensidade de pixels correspondente.



Fonte: do autor.

localização inicial das sementes. Nesta etapa inicial todas as outras células possuem força zero e rótulo indefinido.

**Figura 64** – Inicialização do algoritmo proposto: (a) seleção de sementes; (b) cálculo do centro de massa das sementes; (c) matriz contendo a força inicial de cada célula.

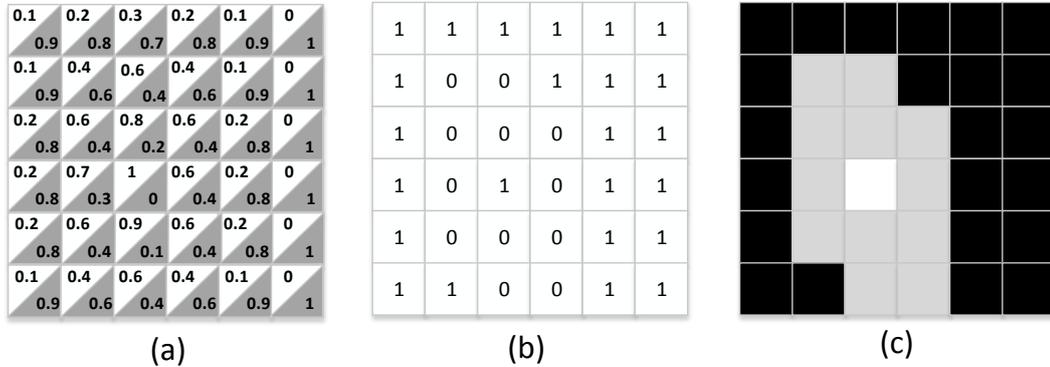


Fonte: do autor.

Cada célula da matriz ataca sua célula vizinha e é atacada baseada em uma região de pertinência Gaussiana. O grau de pertinência é calculado baseado nas equações 5.5 e 5.6. Se usarmos um valor de  $s_x$  e  $s_y$  igual a 4 obtemos os graus de pertinência mostrados na Figura 65 (a). Na Figura 65 (a), cada célula é dividida em duas regiões, indicando o valor de pertinência de cada classe: lesão, representada por um triângulo branco, e fundo, representado por um triângulo cinza. Os graus de pertinência para cada classe irão definir os valores de força e rótulos iniciais, conforme definidos pelas equações 5.4 e 5.7. Baseado na equação 5.4, a Figura 65 (b) mostra os valores iniciais de força obtidos, de acordo com o valores de grau de pertinência referentes a cada célula. A Figura 65 (c) mostra os rótulos iniciais, baseados na equação 5.7 e valores de grau de pertinência, onde as células pretas representando o rótulo da classe de fundo, as células brancas representam o rótulo da classe de lesão, enquanto as células de cor cinza representam as células ainda não rotuladas,

portanto, indefinidas.

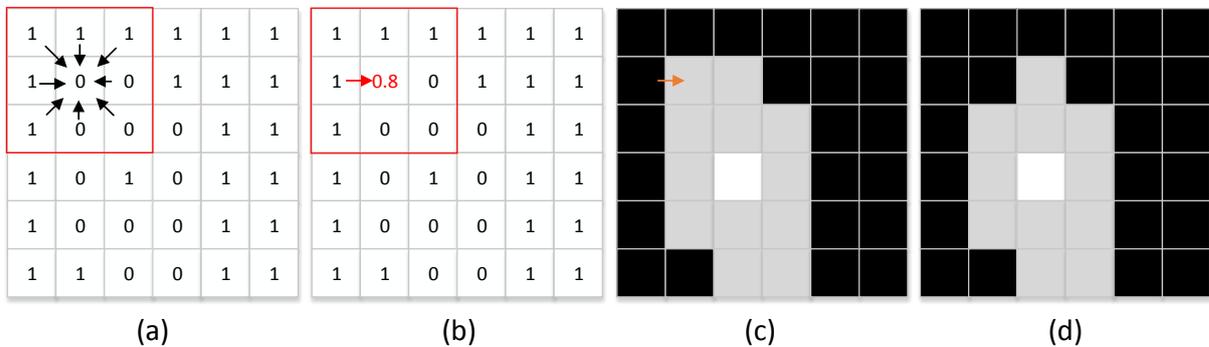
**Figura 65** – (a) Valores de grau de pertinência Gaussiana; (b) valores iniciais das células depois de calcular o grau de pertinência; (c) rótulos iniciais após calcular o grau de pertinência *Fuzzy* Gaussiana.



Fonte: do autor.

A cada iteração do método, cada célula é atacada pelos 8 vizinhos mais próximos, com exceção das bordas. A Figura 66 (a) mostra uma célula sendo atacada pelas células vizinhas. Nesse processo, a força das células atacantes e a diferença de intensidade entre célula atacante e célula defensora irão definir qual das células vizinhas atacantes é a vencedora, conforme definido na linha 10 do Pseudocódigo 3. A força célula defensora é atualizada baseada na força da célula atacante vencedora, conforme representado na Figura 66 (b), onde a seta vermelha indica a célula atacante vencedora. O rótulo da célula defensora também é atualizado baseado no rótulo da célula atacante, como definido na linha 12 do Pseudocódigo 3 e ilustrado na Figura 66 (c) e 66 (d).

**Figura 66** – (a) célula sendo atacada pelos vizinhos mais próximos; (b) atualização de força baseado na força da célula atacante; (c) rótulo sendo atualizado baseado no rótulo da célula atacante; (d) rótulo atualizado.

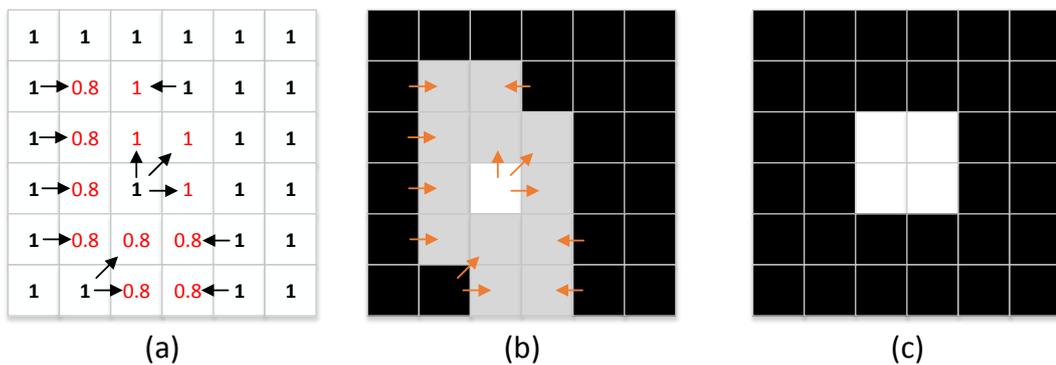


Fonte: do autor.

O processo de uma célula ser atacada pelos vizinhos mais próximos é realizado para todas as células da grade. Quando todas as células tiverem sido atacadas e atualizado

valores de rótulo e força a iteração termina. A Figura 67 (a) mostra o resultado da atualização de força das células no final da primeira iteração. Os valores em vermelho representam as células com valor de força atualizado, enquanto que as setas indicam as células vizinhas vencedoras que influenciaram no processo de atualização. A Figura 67 (b) mostra a atualização dos rótulos no final da primeira iteração, enquanto que as setas mostram as células que influenciaram no processo de atualização. Por fim, a Figura 67 (c) mostra a segmentação final obtida no final da iteração. O algoritmo continua até que nenhuma célula mude seu rótulo no final da iteração, indicando a convergência. No exemplo demonstrado, foi utilizado um caso de estudo simples e foi possível obter a segmentação final em uma única iteração. No entanto, em imagens mais complexas, pode ser necessário um maior número de iterações.

**Figura 67** – Final da primeira iteração: (a) Atualização de força no final da primeira iteração; (b) atualização de rótulos no final da primeira iteração; (c) segmentação final



Fonte: do autor.

A Tabela 16 mostra uma comparação entre o algoritmo GrowCut original e o Modelo proposto. A principal diferença entre o GrowCut clássico e o algoritmo proposto é a tolerância ao posicionamento incorreto de sementes. A introdução da função de pertinência *fuzzy* Gaussiana, que utiliza estatísticas das posições das sementes selecionadas, torna a proposta mais tolerante ao posicionamento incorreto das sementes iniciais, e conseqüentemente, menos dependente do conhecimento especialista para o posicionamento adequado das sementes. Isto significa que o posicionamento inicial se torna mais flexível, sofrendo menos alterações na segmentação devido ao posicionamento incorreto. No entanto, a marcação do especialista ainda é necessária. O processo de inicialização baseado no centro de massa das sementes contribui para o método ser mais flexível com relação ao posicionamento incorreto de sementes. Além disso, o método proposto reduz o esforço necessário para a seleção de sementes, uma vez que requer o uso apenas de sementes internas ao objeto de interesse. Isso acontece porque a região de fundo é determinada pelo complemento da função de pertinência *fuzzy* Gaussiana, responsável por ajustar a força e rótulo de cada célula no processo de atualização. Como o algoritmo é menos dependente

**Tabela 16** – Comparação entre o GrowCut e o Modelo Proposto.

Característica	GrowCut	<i>Fuzzy</i> GrowCut
Seleção de Sementes	Seleção de sementes da classe de objeto e da classe de fundo.	Seleção de sementes apenas da classe do objeto.
Inicialização	Todas as sementes têm força 1, o que é representado pela linha 4 do Pseudocódigo 2: $\Theta_p = 1,$ onde $\Theta_p$ é a força da célula $p$ . Essa atribuição é feita para todas as células onde se localizam as sementes.	Apenas a célula correspondente ao centro de massa da localização das sementes tem força 1, o que é representado na linha 3 do Pseudocódigo 2: $\Theta_{cm} = 1,$ onde $\Theta_{cm}$ é a força da célula correspondente ao centro de massa da localização das sementes.
Segmentação	Baseado no conhecimento da localização das sementes fornecidas pelo usuário.	Baseado no conhecimento da localização das sementes e no modelo <i>Fuzzy</i> -Gaussiano de pertinência de região de objeto e região de fundo.
Regra de Evolução	Baseado na diferença de intensidade e força da célula atacante e célula defensora, representado nas linhas 14 e 15 do Pseudocódigo 2, descrito abaixo: $l_p^{t+1} \leftarrow l_q^t$ $\Theta_p^{t+1} \leftarrow g(\ \vec{C}_p - \vec{C}_q\ _2) \cdot \Theta_q^t$ onde $l_p, l_q, \Theta_p$ e $\Theta_q$ são os rótulos e força das células $p$ e $q$ , respectivamente.	Baseado na função de pertinência <i>fuzzy</i> , na diferença de intensidade e força da célula atacante e célula defensora, como representado nas linhas 14 e 15 do Pseudocódigo 3, descrito abaixo: $l_p^{t+1} \leftarrow l_{M,p,q}^t$ $\Theta_p^{t+1} \leftarrow g(\ \vec{C}_p - \vec{C}_q\ _2) \cdot \Theta_{M,q}^t$ Os valores de $l_{M,p,q}$ e $\Theta_{M,q}$ são definidos pelas equações 5.4 e 5.7, descritas abaixo: $l_{M,p,q} = \begin{cases} l_{bkg}, & \mu_{Bkg}(q) > \mu_{Obj}(q) \\ l_q, & \mu_{Bkg}(q) \leq \mu_{Obj}(q) \end{cases},$ $\Theta_{M,i} = \begin{cases} 1, & \mu_{Bkg}(i) > \mu_{Obj}(i) \\ \Theta_i, & \mu_{Bkg}(i) \leq \mu_{Obj}(i) \end{cases},$ $\mu_{Bkg}(i) = 1 - \mu_{Obj}(i),$ $\mu_{Obj}(i) = \exp\left(-\frac{(x_i - x_m)^2}{2\alpha_x s_x^2}\right) \exp\left(-\frac{(y_i - y_m)^2}{2\alpha_y s_y^2}\right).$ As variáveis de cada equação foram descritas anteriormente nessa seção.
Tolerância a falhas na localização das sementes	Baixa.	Alta.

do conhecimento especialista, ele é também mais interessante para o processo de seleção de sementes não supervisionadas. No entanto a geração automática de sementes tem que garantir que o centro de massa dos pontos estará localizado dentro da região da lesão para que o método possa realizar a segmentação de forma adequada. Como o método é baseado no centro de massa da localização das sementes iniciais, ele permite uma margem de erro, mas se as sementes forem localizadas incorretamente, de tal forma que o centro de massa fique fora da região de lesão, o método poderá gerar uma segmentação incorreta. A regra de evolução proposta difere do GrowCut original porque no GrowCut original ela depende apenas da força da célula atacante e dos valores de intensidade, enquanto que no método proposto também é considerado a função de pertinência *fuzzy*. Como a região de lesão é incerta, é mais adequado utilizar uma função de pertinência *fuzzy* para guiar a atualização das células, onde regiões com maior valor da função de pertinência, relacionadas ao fundo, por exemplo, terão valores de força diferente comparados com regiões com menor valor de

pertinência. Essa modificação permite que o algoritmo esteja menos sujeito a segmentar áreas fora da região de interesse.

### 5.3.1 Seleção Automática de Sementes

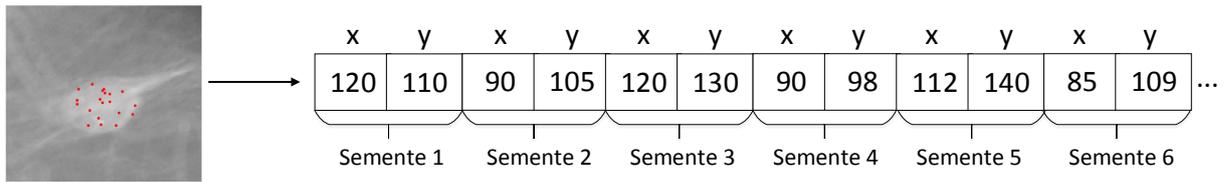
Um modelo de seleção automática de sementes pode ser incorporado ao algoritmo proposto realizar a etapa de inicialização de sementes de forma automática. Ao contrário do GrowCut clássico e de outras técnicas baseadas em semente, como Random Walks (GRADY, 2006) e GraphCut (VICENTE; KOLMOGOROV; ROTHER, 2008), a precisão do modelo de seleção automático de sementes tem um impacto menor no *Fuzzy* GrowCut. Isso se deve ao fato de as sementes iniciais possuírem níveis de pertinência à região de lesão, o que torna o método mais flexível e menos dependente do desempenho do seletor automático.

No processo de seleção automática de sementes, deseja-se que as sementes estejam localizadas nas regiões mais claras da imagem, pois tendem a ser regiões onde há lesão. Também deseja-se que as sementes estejam distribuídas ao longo da região de tumor, e não concentradas em um único ponto. Desta forma, observamos que o problema da localização das sementes geradas é um problema de otimização, onde se deseja otimizar dois objetivos: maximizar a o valor de intensidade onde estão localizadas as sementes e maximizar a distância entre os pontos. Neste trabalho, foi desenvolvido um método de segmentação semi supervisionado que utiliza técnicas de otimização para encontrar as sementes iniciais. Para realizar a etapa de seleção automática de sementes foi utilizado o algoritmo de otimização Evolução Diferencial (*Differential Evolution*, DE) (PRICE; STORN; LAMPINEN, 2005). Esse algoritmo foi escolhido por ser uma técnica de otimização simples, rápida e já validada na literatura, além de possuir poucos parâmetros, conforme mostrado por Das e Suganthan (2011). No entanto, outros algoritmos de otimização, tal como *Simulated Annealing*, descrito por Dowsland e Thompson (2012), também poderiam ser utilizados.

O algoritmo Evolução Diferencial se baseia em uma população inicial, composta por indivíduos, que são as soluções do problema, estes indivíduos sofrem alterações ao longo das iterações, a fim de se obter o melhor conjunto de soluções. Para utilizar o algoritmo Evolução Diferencial no problema de geração automática de sementes, inicialmente foi necessário realizar o mapeamento da solução para o problema. Para o mapeamento do problema, cada solução é composta por um conjunto de sementes na imagem, sendo cada semente composta por dois atributos: posição no eixo  $x$  e posição no eixo  $y$ . A partir da localização da semente é possível estimar a intensidade do *pixel* correspondente à sua posição. A Figura 68 mostra o exemplo de mapeamento de um indivíduo.

Conforme mostrado na Figura 68, uma solução do processo de otimização é um vetor contendo a posição nos eixos  $x$  e  $y$  do conjunto de sementes. No algoritmo Evolução Diferencial define-se uma população de solução candidatas, onde buscam-se soluções que

**Figura 68** – Mapeamento do indivíduo no modelo de geração automática de sementes.



Fonte: do autor.

otimizem uma determinada função objetivo. Para realizar a otimização, foi definida uma função de otimização multi-objetivo para avaliar a qualidade das soluções, a qual se baseia em maximizar dois objetivos: intensidade dos *pixels* na localização das sementes e distância euclidiana entre as mesmas. Desta forma, quanto maior a intensidade do pixel da localização das sementes, e quanto mais separadas elas estiverem entre si, melhor a solução. Para avaliar se uma solução é melhor do que a outra foi utilizado o conceito de dominância, definido na seção 3.2.4. Uma vez encontrado um *pareto* com soluções equivalentes, é escolhida a solução do *pareto* com maior valor médio de intensidade de *pixel* das sementes.

---

#### Pseudocódigo 4 Evolução Diferencial

---

```

1: Gere uma população inicial  $x^{i,0}$ ,  $i = 1, \dots, P$  e avalie aptidão
2: Seja  $F$  um valor real entre 0 e 1
3: for  $g = 1, \dots, MAXGEN$  do
4:   for  $k = 1, \dots, P$  do
5:     for  $i = 1, \dots, M$  do
6:       Selecione aleatoriamente  $r_1 \neq r_2 \neq r_3 \neq k \in \{1 \dots P\}$ 
7:        $r_{nbr} \leftarrow randint(1, n)$ 
8:       for  $j = 1, \dots, n$  do
9:         if  $rand(0, 1) \leq CR$  ou  $j = r_{nbr}$  then
10:           $filhos_j^{k,i} \leftarrow x_j^{r_3,g} + F * (x_j^{r_1,g} - x_j^{r_2,g})$ 
11:        else
12:           $filhos_j^{k,i} \leftarrow x_j^{k,g}$ 
13:        end if
14:      end for
15:    end for
16:    Seja  $u^k$  a melhor solução dentre  $x^{k,g}$  e  $filhos^{k,i}$ ,  $i = 1, \dots, M$ 
17:     $x^{k,g+1} \leftarrow u^k$ 
18:  end for
19: end for

```

---

O funcionamento do algoritmo Evolução Diferencial é mostrado no Pseudocódigo 4. No Pseudocódigo 4, a variável  $M$  representa o número de soluções novas por geração,  $CR$  é a taxa de cruzamento,  $MAXGEN$  é o número máximo de gerações e  $n$  é o número de elementos do vetor que representa a solução. De acordo com o Pseudocódigo 4, a geração

de novas soluções é feita através de um operador de mutação, que realiza combinação linear entre três soluções da população, um operador de cruzamento, que mistura coordenadas do vetor gerado pelo operador de mutação, e um operador de cruzamento, que mistura coordenadas do vetor gerado pelo operador de mutação. A última solução competirá com a nova solução gerada pela permanência na população. Se a nova solução obtida for melhor que a solução de cruzamento de acordo com algum critério de seleção pré-estabelecido, então a solução de cruzamento será substituída pela nova solução gerada. O critério de avaliação das soluções é baseado na função de aptidão, que é definida de acordo com o objetivo a ser otimizado por cada problema. O processo é repetido até atingir o número máximo de gerações. Os parâmetros utilizados no algoritmo são mostrados na Tabela 17.

**Tabela 17** – Parâmetros utilizados no algoritmo Evolução Diferencial para a geração automática de sementes.

Parâmetro	Melhor Valor	Variação
Tamanho da População	20	[10,20,30]
Número máximo de iterações	3000	[2000,3000,4000,5000]
CR	0,9	[0,6, 0,7, 0,8, 0,9]

A primeira coluna da Tabela 17 descreve os parâmetros do algoritmo, descritos na seção ??, a segunda coluna mostra o melhor valor de configuração obtido empiricamente, e a terceira coluna mostra a variação de valores testados.

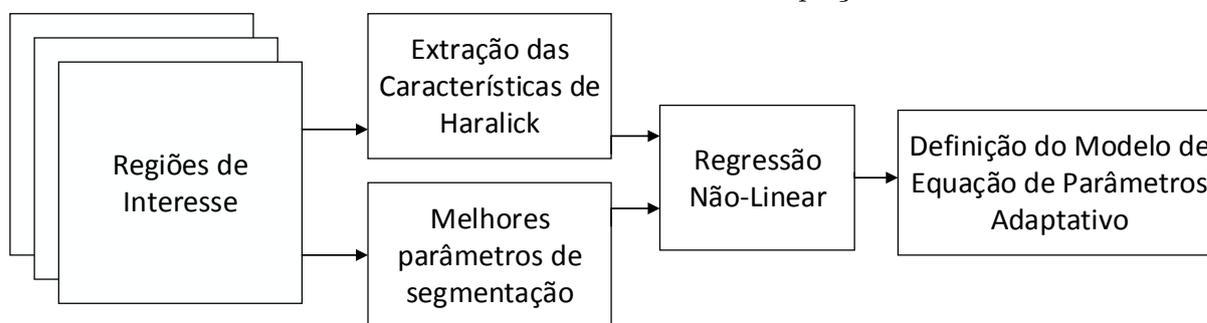
### 5.3.2 Seleção Adaptativa de Parâmetros

O modelo proposto baseado no GrowCut requer a configuração de dois parâmetros: o número de pontos que representam a solução no algoritmo de Evolução Diferencial e o valor de  $\alpha$  da função de pertinência *fuzzy-gaussiano*, descrito na Equação 5.6. No entanto, a melhor configuração pode variar de acordo com a região de interesse selecionada, assim como a maioria dos algoritmos descritos no Capítulo 4. Um dos problemas é que a seleção dos parâmetros ainda requer um conhecimento especialista, o qual depende da experiência do profissional e está sujeito à falha humana. Apesar de o processo de segmentação proposto ser automático, a seleção de parâmetros ainda requer a configuração realizada por um especialista. No entanto, esse processo de seleção de parâmetros pode ser automatizado a partir da definição de uma equação que mapeie as características da região de interesses escolhida e os melhores parâmetros do algoritmo proposto.

O modelo de equação de parâmetros adaptativo consiste em sugerir uma configuração para o algoritmo GrowCut *fuzzy-gaussiano*, baseado nas características da região de interesse. Porém, essa equação não é conhecida, e foi assumido que esse modelo pode ser aproximado através de uma equação quadrática, usando o método de regressão não-linear. Para obter a definição do modelo de equação de parâmetros adaptativo, inicialmente

foi realizado uma busca exaustiva no espaço de configurações do GrowCut *Fuzzy* para encontrar os melhores parâmetros de configuração para cada ROI da base de dados. Em seguida, foi aplicado um método de regressão não-linear baseado nas características das ROIs e os melhores parâmetros de segmentação de cada ROI. Anteriormente foi aplicado uma abordagem mais simples, utilizando regressão linear, porém não obtivemos sucesso. Os resultados da regressão não-linear fornecem a definição do modelo de equação de parâmetros adaptativo. Esse processo foi realizado apenas uma única vez para definir a equação de parâmetros. Esse fluxo é mostrado na Figura 69.

**Figura 69** – Fluxograma da Definição do Modelo de Equação de Parâmetros Adaptativo. Esse processo foi realizado apenas um única vez para definir o modelo de equação.



Fonte: do autor.

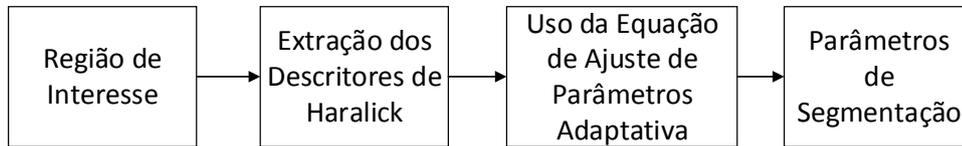
Para realizar a regressão, inicialmente foram extraídas as características de Haralick de todas as ROIs da base. Para cada região de interesse também foram identificados os melhores parâmetros de segmentação. O modelo de regressão não-linear é aplicado utilizando as características de Haralick de cada imagem, juntamente com os respectivos melhores parâmetros, obtendo o modelo de equação de parâmetros adaptativo. No modelo de regressão não-linear, foram utilizados como entrada os 13 parâmetros de Haralick descritos na seção 3.1.11.2 e os melhores parâmetros de segmentação como saída desejada para regressão. A equação de geração de parâmetros é aproximada por uma função, a qual é representada pela Equação 5.8:

$$f(x_1, x_2, \dots, x_{13}) = w_0 + \sum_{i=1}^{13} w_i \cdot x_i + \sum_{i=1}^{13} \sum_{k=1}^{13} w_{13i+k} \cdot x_i \cdot x_k, \quad (5.8)$$

onde  $x_1, x_2, \dots, x_{13}$  representa as 13 características de Haralick e  $w_i$  é o  $i$ -ésimo peso da função. A equação é composta por 105 pesos, cujos valores são fornecidos como resultado da regressão. A equação de parâmetros adaptativa mapeia a relação entre as características de Haralick e as melhores configurações do algoritmo. Portanto, uma vez estimados os pesos da equação, é necessário apenas fornecer os descritores de Haralick de uma ROI para obter a predição dos melhores parâmetros para o algoritmo. A Figura 70 mostra o

processo de configuração automático dos parâmetros de segmentação, o qual é usado para cada ROI da base de dados.

**Figura 70** – Ajuste automático dos parâmetros de segmentação.



Fonte: do autor.

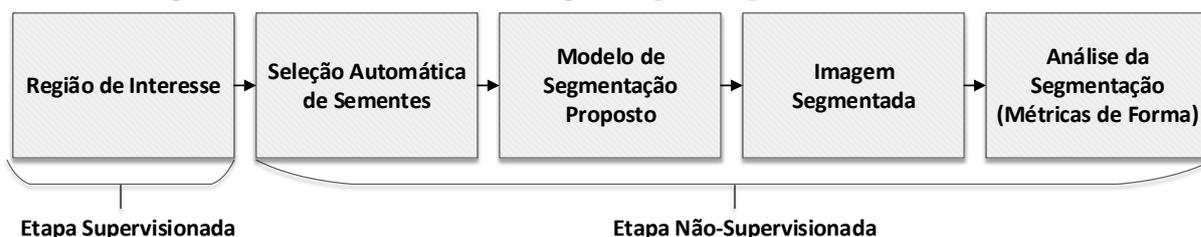
Esse processo torna o método adaptativo porque uma vez definida a equação de configuração de parâmetros, com pesos estimados através da regressão não-linear, é necessário apenas encontrar os descritores de Haralick para cada região de interesse para obter os parâmetros de segmentação adequados.

Para a geração do modelo de equação de parâmetros adaptativos na base Mini-MIAS, foi realizada uma expansão na base, utilizando ruído Gaussiano nas 57 ROIs, criando um conjunto de 171 regiões de interesse. Essas 171 imagens foram utilizadas para estimar a equação de ajuste de parâmetros adaptativa. No entanto, para a análise da segmentação, foram usadas as 57 imagens originais. A expansão com ruído gaussiano foi utilizada porque o número de imagens era pequeno. Para a base IRMA, a equação de ajuste de parâmetros foi definida a partir das imagens originais analisadas.

### 5.3.3 Fluxo de Simulação

Nessa seção é descrito o fluxo de simulação do algoritmo proposto. O fluxo da Figura 78 ilustra a metodologia aplicada para a realização da segmentação. O processo começa com uma região de interesse inicial, que corresponde a seleção prévia por um especialista ou algoritmo computacional. Para este trabalho as regiões de interesse do Mini-MIAS foram selecionadas manualmente, baseadas nas indicações de localização da base. Em seguida, é realizada a seleção automática de pontos, o qual modela a localização das sementes em um problema de otimização, no qual os objetivos são maximizar a intensidade dos *pixels* semente e manter um espalhamento entre eles. Para a seleção automática de sementes, foi utilizado o algoritmo Evolução Diferencial. Após os *pixels* semente serem obtidos, eles são utilizados como entrada para o modelo proposto, gerando como saída a imagem segmentada. Desta forma, uma vez fornecida a região de interesse inicial, o processo de segmentação é realizado automaticamente. Após obtida a imagem segmentada, são aplicadas as métricas relacionadas à forma para validar a qualidade da segmentação.

A Figura 72 mostra um exemplo das etapas da metodologia aplicada a imagem mdb132, do Mini-MIAS. A coluna *a* da Figura 72 mostra a região de interesse selecionada manualmente. A coluna *b* mostra as sementes, em vermelho, geradas pelo método de

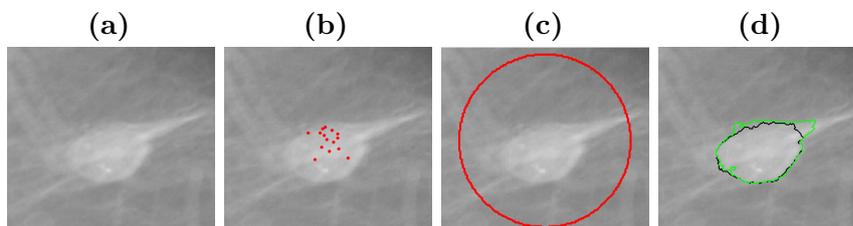
**Figura 71** – Fluxo da Metodologia Proposta aplicada à base Mini-MIAS

Fonte: do autor.

seleção automática. Como descrito no capítulo 5, o método proposto requer apenas a seleção de sementes da região de lesão. A coluna  $c$  mostra os limites da região *fuzzy* Gaussiana, onde a região interna tem maior grau de pertinência dos *pixels* em relação à lesão. O tamanho da região Gaussiana é baseado na localização das sementes. Por fim, a coluna  $d$  apresenta a comparação do contorno da imagem sementada com o contorno da imagem ouro. Nessa etapa são aplicadas as métricas relacionadas à forma da lesão.

**Figura 72** – Etapas da metodologia aplicada a imagem mdb132, do Mini-MIAS.

(a) Imagem Original; (b) Geração automática de sementes; (c) Região *Fuzzy* Gaussiana (d) segmentação final comparada com a imagem ouro.

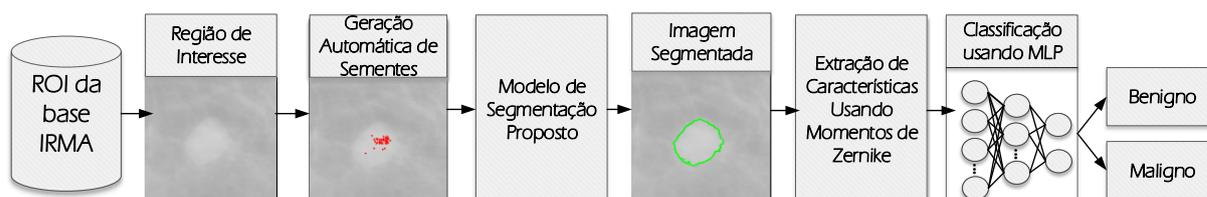


Fonte: do autor.

O fluxograma da Figura 74 ilustra o algoritmo proposto aplicado para a classificação de imagens segmentadas na base IRMA. Na base IRMA todas as imagens já são originalmente disponibilizadas no formato de região de interesse, contendo apenas a região da lesão. Uma vez obtida a imagem da base é utilizado o mesmo processo utilizado para gerar a imagem segmentada. A diferença para a base IRMA é o processo de análise dos resultados. Uma vez que a mesma não oferece imagem ouro, foi utilizado o método de validação baseado na taxa de classificação das imagens segmentadas.

#### 5.4 CONSIDERAÇÕES DO CAPÍTULO

Neste capítulo foi realizada uma validação do algoritmo GrowCut, comparando com técnicas supervisionadas utilizadas no estado da arte. A análise mostrou que o algoritmo GrowCut obteve melhores resultados de segmentação quando comparado com as técnicas Contornos Ativos, Random Walks e Crescimento de Região e GraphCut. Além

**Figura 74** – Fluxo da Metodologia Proposta aplicada à base IRMA.

Fonte: do autor.

de obter melhores resultados de segmentação, o método GrowCut é um bom candidato para adaptação pois não apresenta parâmetros, é simples e paralelizável.

Também foi apresentado o modelo proposto, onde foi descrito um novo modelo de segmentação baseado em sementes. Esse modelo é inspirado no modelo GrowCut, mas possui regras de atualização de rótulo e inicialização baseadas em um modelo *fuzzy*-gaussiano, que estima uma região de pertinência dos *pixels* à região de lesão. Com isso, o modelo torna-se mais flexível a seleção incorreta de sementes, o que permite que sejam utilizados métodos não supervisionados para seleção de sementes. Além disso, no modelo proposto não é necessária a seleção de sementes da classe de fundo, sendo necessário apenas a seleção das sementes da classe de objeto. Desta forma, o modelo proposto reduz a necessidade de conhecimento especialista sobre a localização da lesão e formula uma nova abordagem de segmentação por sementes, baseada em uma região *fuzzy*-gaussiana.

Além disso é possível adicionar um método de seleção automática de sementes, para eliminar a necessidade de conhecimento especialista para seleção inicial dos pontos. Para, isso foi proposta uma função objetivo para ser utilizado junto a uma técnica de otimização. Também foi proposto um modelo multi-objetivo de geração automática de sementes, o qual elimina a necessidade de parâmetros para a função objetivo. Devido à flexibilidade do modelo proposto, o impacto do desempenho do método de seleção de sementes é reduzido. Além disso, o modelo proposto elimina a necessidade da seleção de sementes fora do objeto de interesse.

Por fim, é apresentado também um método automático de seleção de parâmetros para o algoritmo proposto, o qual é definido uma equação de ajuste de parâmetros, realizada uma única vez por meio do uso de regressão não-linear. Com essa equação, cujos pesos foram encontrados através da regressão, a cada nova região de interesse, é necessário apenas calcular os descritores de Haralick para obter a estimativa de melhores parâmetros para aquela imagem. Desta forma, o algoritmo se torna adaptativo para cada região de interesse e é eliminada a necessidade de otimização de parâmetros.

## 6 MATERIAIS E MÉTODOS

Este capítulo apresenta a metodologia utilizada na tese, descrevendo o fluxo de projeto, fluxo de simulação, ambiente experimental e métricas de avaliação utilizados. A metodologia apresentada neste capítulo pode ser facilmente estendida para outros tipos de análise de imagens médicas.

A metodologia aplicada nesse trabalho é descrita nesse capítulo através do detalhamento do fluxo de desenvolvimento, descrição das técnicas implementadas, ambiente experimental e métricas de análise. A seguir é descrito o fluxo de desenvolvimento do projeto.

### 6.1 FLUXO DE DESENVOLVIMENTO DO PROJETO

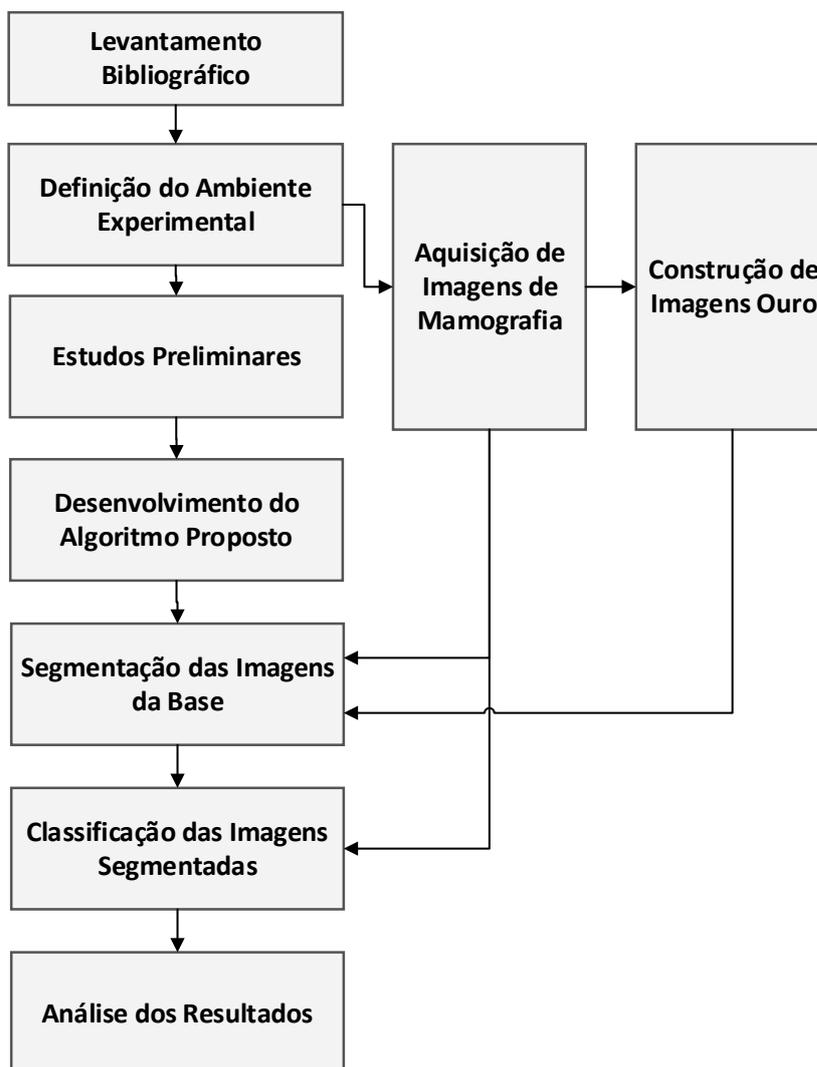
O fluxo de desenvolvimento do projeto mostra todas as etapas envolvidas na implementação da Tese. A Figura 75 mostra o fluxo de projeto para o desenvolvimento do trabalho.

Inicialmente foi realizado o levantamento bibliográfico, descrito no capítulo 4, onde foi feito um estudo sobre as principais técnicas de segmentação na área. Ao analisar os trabalhos no estado da arte foi observado a ausência de técnicas supervisionadas robustas quanto à marcação inicial fornecida pelo usuário. Devido a essa ausência de robustez, técnicas híbridas não obtêm boa qualidade de segmentação, pois não há garantias de que a geração automática de sementes seja precisa para a maioria dos casos. Em virtude desse levantamento definiu-se o objetivo da construção de um novo método semi-supervisionado robusto quanto ao posicionamento inicial das sementes.

Com o levantamento bibliográfico, foi observado quais bases de dados são utilizadas no estado da arte e foi feita a definição do ambiente experimental, onde foram selecionadas as bases de dados de mamografia digital e definido o conjunto de imagens a ser trabalhado. A partir da base adquirida foi realizada a construção das imagens ouro da base. A construção da imagem ouro é necessária, pois as bases adquiridas não possuem a marcação do especialista. No entanto, para realizar a análise da qualidade da segmentação é necessário comparar com a imagem ouro. A descrição das bases e construção das imagens ouro será detalhado na próxima seção 6.2.

Após essa etapa foram realizados estudo preliminares com os algoritmos de segmentação do estado da arte. Conforme descrito na seção 4.4, foi identificado que entre os métodos de segmentação supervisionados utilizados em imagens médicas, o GrowCut é um bom candidato por não apresentar nenhum parâmetro, ser um método baseado em região, paralelizável, simples, e com potencial para inserção de um modelo de incerteza.

Figura 75 – Fluxo de Desenvolvimento do Projeto



Fonte: do autor.

No entanto, para validar o GrowCut como algoritmo competitivo para segmentação de lesões, foi realizado o estudo comparativo com outras técnicas supervisionadas utilizadas no estado da arte.

A partir do estudo da validação do GrowCut, confirmou-se o GrowCut como técnica de segmentação de lesões competitiva com estado da arte, com a vantagem de ausência de parâmetros além das sementes iniciais. A partir daí foi realizado o desenvolvimento do algoritmo proposto, a partir da inserção de um modelo *fuzzy* gaussiano no GrowCut, modificando as equações e propondo uma nova forma de realizar segmentação de lesões, com menor esforço inicial e robusta quanto ao posicionamento inicial de sementes. Em seguida foi adicionado um método de geração automática de sementes, tornando o método semi-supervisionado. A descrição detalhada do algoritmo e a explicação do porquê da inserção de um modelo *fuzzy* gaussiano é realizada no capítulo 5.

Posteriormente foi feita a segmentação das imagens das bases adquiridas utilizando o método proposto e comparado com trabalhos do estado da arte. O fluxo de simulação para segmentação das imagens da base é descrito nesse capítulo na seção 6.3. Em seguida foi realizada uma análise de classificação a partir das imagens segmentadas, para avaliar a qualidade da segmentação.

Por fim, foi realizada a análise dos resultados, utilizando as métricas que serão descritas nesse capítulo, na seção 6.5. As análises foram realizadas de forma qualitativa e quantitativa, comparado o método proposto com as técnicas do estado da arte. Os resultados obtidos são detalhados no capítulo 7.

## 6.2 AMBIENTE EXPERIMENTAL

O trabalho proposto utiliza duas bases de dados para realizar a avaliação das técnicas: a Mini-MIAS (SUCKLING et al., 1994), e a IRMA (DESERNO et al., 2011). Nas subseções a seguir são descritas as características e composição de cada base.

A abordagem do trabalho proposto baseia-se em um sistema que irá receber como entrada a região de interesse selecionada previamente por um especialista. Uma vez que a região de interesse é obtida, ela é submetida como entrada para os algoritmos de segmentação. A maioria das técnicas que buscam regiões de interesse não fornecem uma análise qualitativa da segmentação em termos da forma da lesão. Uma vez que a qualidade do contorno da segmentação é importante para definir o tipo da lesão, é importante ter melhores algoritmos para otimizar o contorno final da segmentação. Algumas bases de dados, como o IRMA, são compostas apenas por regiões de interesse, chamados de *patches*. Vários trabalhos recentes, como os de Esener, Ergin e Yuksel (2015), Sharma e Khanna (2013), Sharma e Khanna (2015), se baseiam em regiões de interesse fornecidos por especialistas para realizar suas análises.

Todas as técnicas foram implementadas utilizando o *software MatLab* (MATLAB, 2011), rodando em um computador *Intel Core i7*, com 8GB de memória *RAM*.

### 6.2.1 Mini-MIAS

A base de dados Mini-MIAS é uma base de dados pública, onde as imagens foram adquiridas a partir do programa nacional de triagem de mama do Reino Unido, as quais foram digitalizadas a  $50 \mu m$ . A base de dados foi reduzida a  $200 \mu m$  de tamanho de *pixel* e foi preenchida e cortada de modo que todas as imagens possuem a resolução de  $1024 \times 1024$  *pixels* e 8 *bits* de precisão (tons de cinza). Além disso, a base de dados contém indicações da localização da lesão para cada imagem. A base contém 322 imagens de mamografia mediolateral-oblínquo (MLO) retiradas de 161 pacientes, a qual apenas 56 imagens possuem lesões, sendo classificadas de acordo com a margem em três tipos: circunscrita, espiculada

e indefinida. A Tabela 18 mostra a composição de imagens da base de dados.

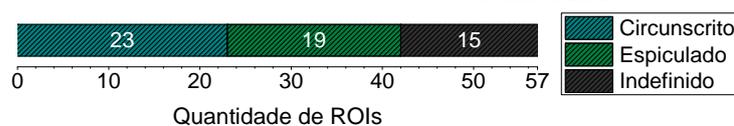
**Tabela 18** – Quantidade de imagens de cada tipo na base de dados Mini-MIAS.

Tipo	Quantidade
Circunscrito	23
Espiculado	19
Indefinido	14
Normal	207
Distorção Arquitetural	19
Assimetria	15
Calcificação	25
Total	322

Conforme descrito na Tabela 18, existe um grande conjunto de imagens que não contém lesão, tais como as imagens classificadas como normal ou outro tipo de anormalidade, como distorção arquitetural, assimetria e calcificação.

Neste trabalho, das 56 imagens com lesão, apenas uma imagem foi descartada, a *mdb059*, pois a base não fornecia indicação da região de lesão. A partir das imagens da base, foram selecionadas manualmente regiões de interesse baseadas na indicação de localização da base. Das 55 imagens restantes com lesão, 2 imagens haviam 2 regiões de interesse, por possuírem 2 lesões na mesma imagem, totalizando assim 57 regiões de interesse. A partir dessa base de dados um total de 57 ROIs foram utilizadas, sendo compostas da seguinte forma: 25 circunscritas, 19 espiculadas e 15 indefinida, como mostra a Figura 76.

**Figura 76** – Quantidade de regiões de interesse por tipo de lesão usadas para a base de dados Mini-MIAS.



Fonte: do autor.

Apesar da base fornecer a localização da lesão e o raio aproximado, não é suficiente para realizar a análise de qualidade da segmentação quanto à forma da imagem obtida. Para isso, foi necessário a construção das imagens ouro a partir das indicações fornecidas pelo Mini-MIAS. As imagens ouro, que são as imagens de segmentação esperada, foram obtidas por um *software* supervisionado auxiliar, baseado em limiar adaptativo, o qual usa as indicações fornecidas pela base de dados para definir o contorno esperado de cada imagem.

As regiões de interesse foram recortadas manualmente, baseados nas informações de localidade das lesões, possuindo tamanhos diferentes cada cada imagem.

### 6.2.2 IRMA

Este trabalho também usa a base de dados IRMA, elaborada a partir de um projeto desenvolvido pela Universidade Aachen (RWTH Aachen) (OLIVEIRA et al., 2010; DESERNO et al., 2012), na Alemanha, que reúne imagens de outras bases, disponíveis para consulta na internet. A base de dados é toda formada por regiões de interesse de imagens de mamografia digital, as quais foram classificadas por radiologistas e redimensionadas para imagens de tamanho  $128 \times 128$  pixels. A base IRMA contém 2.796 imagens de mamografia de 4 diferentes repositórios: 150 imagens do Mini-MIAS, 2.576 imagens do DDSM (HEATH et al., 2000), 1 da base LLNL (ASHBY et al., 1995), e 69 do Departamento de Radiologia da *Aachen University of Technology* (RWTH), Alemanha. As imagens da base possuem densidades de tecido que são classificadas em quatro tipos, de acordo com a classificação do BIRADS (D'ORSI et al., 1998): tecido adiposo (tipo I), tecido fibrograndular (tipo II), tecido denso (tipo III) e tecido extremamente denso (tipo IV).

Para o trabalho proposto foram analisadas, no estudo de classificação, todas as imagens do tipo I e tipo II, com lesão do tipo circunscrito, espiculado, indistinto e sem lesão (normal), totalizando 1.165 imagens. As imagens não utilizadas da base compõem imagens com tecido do tipo III e tipo IV e imagens com outros tipos de lesão: calcificação, distorção arquitetural e assimetria. Essas imagens foram descartadas porque fogem ao escopo do trabalho. A Tabela 19 mostra o número de imagens utilizadas, para cada tipo de tecido e lesão, o que corresponde ao total de imagens disponíveis na base para tecido do tipo I e II, com imagens sem lesão, circunscrito, espiculado e indistinto.

**Tabela 19** – Número de imagens usadas da base IRMA na separado por tipo de lesão e tecido.

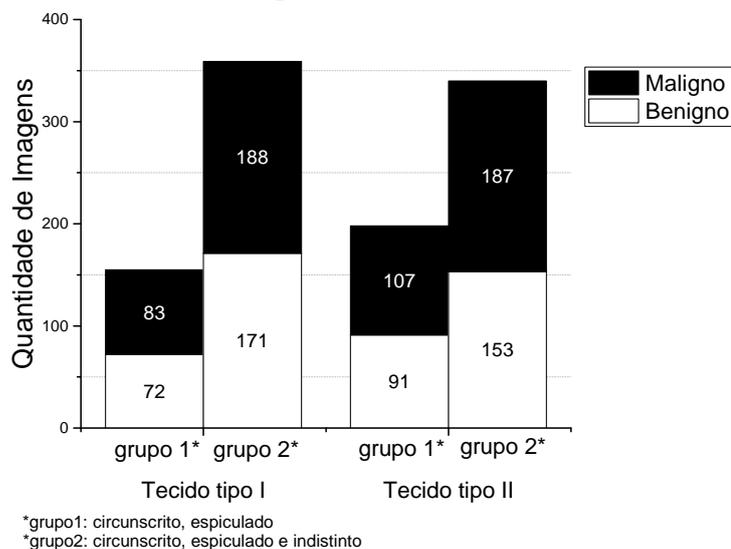
Tipo de Tecido	Lesão				Total
	normal	circunscrito	espiculado	indistinto	
I	233	93	62	204	592
II	233	98	100	142	573
Total	699	191	162	346	1165

A distribuição entre imagens com lesão que indica a presença de tumor benigno e maligno para as imagens utilizadas é apresentada na Figura 77. A representação é dividida em dois grupos, um contendo apenas lesões do tipo circunscrito e espiculado, e outro contendo circunscrito, espiculado e indistinto. A Figura 77 é apresentada com essa divisão pois na etapa de avaliação são analisados os resultados baseado nesses dois grupos.

A Figura 77 mostra que existe uma proporção próxima de 50% entre lesões com tumor benigno e maligno, para os grupos a serem analisados.

A base IRMA não possui indicações da localização da lesão nem fornece imagem ouro. Ela possui apenas a rotulação quanto ao tipo e forma da lesão. Para realizar a

**Figura 77** – Proporção entre imagens com lesões benignas e malignas utilizadas para a base de dados IRMA.



Fonte: do autor.

comparação da qualidade de segmentação para a base IRMA foi necessário realizar a marcação manual do contorno da lesão, para criar a imagem ouro de cada imagem. Para realizar a marcação contamos com a colaboração de uma especialista na área de mamografia, que realizou a marcação de forma manual, de acordo com sua experiência profissional. Esse processo foi realizado para todas as imagens da base IRMA, considerando imagens com lesões circunscritas e espiculadas, para o tipo de tecido I e II, totalizando 353 imagens. Nesse processo, as imagens que a especialista não se sentiu confiável para realizar a marcação foram descartadas. Imagens com lesão do tipo indefinido não foram incluídas devido ao aumento no esforço necessário para realizar as marcações de forma manual. A Tabela 20 mostra o número de imagens de cada tipo, indicando o número de imagens marcadas pelo profissional e o número de imagens disponíveis na base.

**Tabela 20** – Número de imagens com imagem ouro da base IRMA separado por tipo de lesão e tecido.

Tipo de Tecido	Lesão				Total	
	circunscrito		espiculado		marcado	disponível
	marcado	disponível	marcado	disponível		
I	81	93	55	62	136	155
II	96	98	91	100	187	198
Total	177	191	146	162	323	353

Conforme mostrado na Tabela 20, considerando lesões do tipo circunscrito e espiculado, apenas 30 imagens foram descartadas. As imagens descartadas estão listadas no Apêndice B, na Tabela 54. Para a análise de classificação, todas as imagens do tipo I e

tipo II foram utilizadas.

### 6.3 FLUXO DE SIMULAÇÃO

Nessa seção é descrito o fluxo de simulação utilizado para realização da análise de segmentação e para análise de classificação dos algoritmos implementados. Para a análise de segmentação da base Mini-MIAS e IRMA foi realizado um estudo aplicando métricas relacionadas à similaridade entre a forma das lesões segmentadas com a forma da imagem ouro. Para a análise de classificação foi utilizado um método de avaliação baseado na taxa da classificação das imagens segmentadas em lesões com tumores benignos ou malignos. Essa análise se baseia no princípio de que se um classificador consegue realizar uma boa classificação apenas baseado nas imagens segmentadas, então as imagens possuem uma qualidade adequada de segmentação para utilização na prática clínica.

Essa seção está dividida em duas subseções: uma contendo o fluxo de análise de segmentação de lesões e outra contendo o fluxo de análise para classificação.

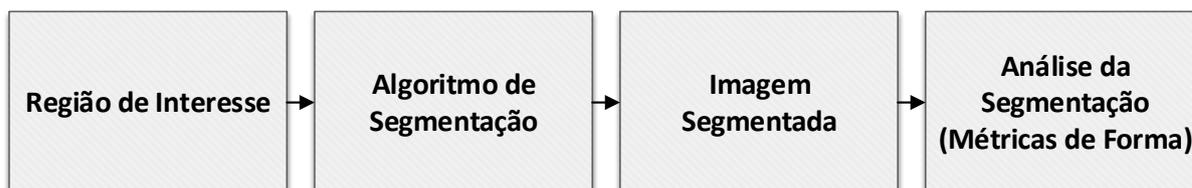
#### 6.3.1 Fluxo de Análise de Segmentação

O fluxo da Figura 78 ilustra a fluxo de análise de segmentação, aplicado tanto para as bases Mini-MIAS e IRMA, que foram utilizados para os métodos analisados. Para a base Mini-MIAS foram utilizadas 57 imagens e para a IRMA foram utilizadas 353 imagens. A processo começa com uma região de interesse inicial, que corresponde a seleção prévia realizada por um especialista ou por um método não supervisionado. Para este trabalho, as regiões de interesse da base Mini-MIAS foram selecionadas manualmente, baseadas nas indicações de localização da base, selecionando o tamanho da região de interesse manualmente, baseado no tamanho da lesão. As mesmas regiões de interesse foram utilizadas para todas as técnicas. Para a base IRMA já é disponibilizada uma região de interesse pela própria base. Uma vez obtida a região de interesse, é aplicado o algoritmo de segmentação. Apesar de alguns algoritmos serem originalmente capazes de realizar a segmentação a partir da imagem original, para o estudo comparativo foi realizada a segmentação a partir da região de interesse selecionada. Após a aplicação do algoritmo de segmentação, a imagem segmentada é obtida. A partir da imagem segmentada, são aplicadas métricas relacionadas à forma, comparado a segmentação do algoritmo com a segmentação desejada, representada pela imagem ouro.

#### 6.3.2 Fluxo de Análise de Classificação

O fluxograma da Figura 79 ilustra fluxo de análise de classificação, o qual foi utilizado para 699 imagens da base IRMA. Na base IRMA todas as imagens contém informação sobre o tipo do tumor presente na lesão: benigno ou maligno. Desta forma, foi possível utilizar todas as imagens contendo lesão do tipo circunscrito, espiculado e

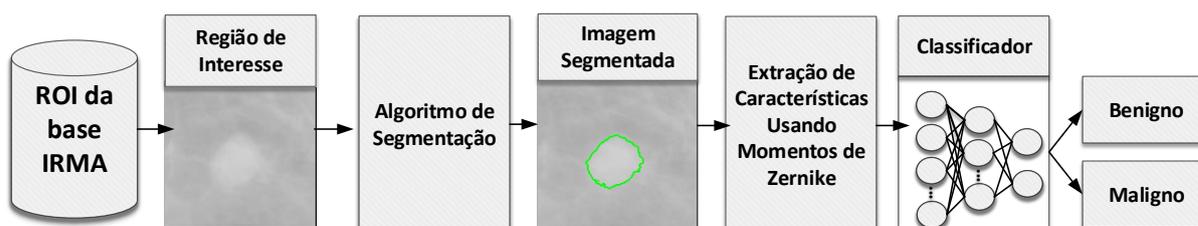
**Figura 78** – Fluxo da Metodologia Proposta para análise da qualidade de segmentação dos métodos utilizados.



Fonte: do autor.

indistinto, para os tecidos do tipo I e tipo II. Uma vez que a base IRMA não oferece imagem ouro e não foi possível obter a segmentação manual pela especialista para todas as imagens, foi utilizado um método de validação dos resultados baseado na taxa de classificação das imagens segmentadas.

**Figura 79** – Fluxo de Análise de classificação das imagens segmentadas aplicada à base IRMA.



Fonte: do autor.

Conforme mostra a Figura 79, o processo começa com a utilização da região de interesse já fornecida pela base IRMA. A partir da ROI, é aplicado algoritmo de segmentação, obtendo-se a imagem segmentada. Para a validação, são extraídas as características da imagem segmentada utilizando os momentos de Zernike, que são descritores de forma e margem. Neste trabalho, foram utilizados os 64 Momentos de Zernike. As características extraídas são utilizadas como entrada para o classificador MLP, que classifica o lesão em benigno ou maligno. A análise é feita baseada na taxa de classificação, onde uma alta taxa de acerto indica que a imagem segmentada oferece informações suficientes para o uso delas no diagnóstico médico. Informações sobre o classificador são fornecidas na seção 6.5.1.

#### 6.4 TÉCNICAS COMPARADAS

O método proposto foi comparado com técnicas não supervisionadas do estado da arte. No entanto, como o modelo proposto é um modelo semi-supervisionado, fez-se uma adaptação para as técnicas comparadas serem semi-supervisionadas. A adaptação consiste apenas no uso da região de interesse da localização da lesão ao invés do uso da imagem original, para todas as técnicas comparadas.

Para a comparação com o algoritmo GrowCut clássico foi utilizada a implementação disponível por (LANKTON, 2008). O desenvolvimento do modelo proposto foi realizado através de implementações e modificações nessa versão da implementação.

Neste trabalho foram realizadas comparações com cinco técnicas do estado da arte de segmentação de lesão de imagem de mamografia: BEMD, BMCS, MCW, Abordagem Topográfica e WAGA. A escolha das técnicas foi baseada na busca das técnicas com melhores resultados quanto à qualidade da segmentação de cada técnica. Conforme descrito no capítulo 4, as métricas do estado da arte variam bastante dependendo do autor, tornando-se difícil a comparação entre as técnicas. A métrica mais comum entre os autores é a métrica de sobreposição de *pixels*, descrita na seção a seguir, porém ela não reflete com precisão a qualidade de segmentação de lesão. No entanto, essa métrica foi utilizada como fator de escolha para definir os trabalhos a serem comparados. Para realizar a análise comparativa, utilizou-se a métrica de sobreposição, presente em trabalhos do estado da arte, mas foram adicionadas métricas com melhor relação quanto à forma do objeto segmentado. Essas métricas são descritas na seção a seguir.

## 6.5 MÉTRICAS DE ANÁLISE

A análise dos resultados realizada para a base Mini-MIAS é baseada em nove métricas. As métricas foram escolhidas baseadas nas métricas mais utilizadas no estado da arte e em métricas relacionadas à forma da região segmentada. A fim de avaliar a precisão da forma entre a região segmentada e a imagem ouro, as seguintes métricas foram utilizadas: Área, Perímetro, Fator de Forma, Solidez, Distância de *Feret*, Área Sobreposta e Espectro de Padrões. Para avaliar verdadeiros e falsos positivos foram usadas as seguintes métricas: Sensibilidade, Especificidade e Acurácia Balanceada.

A Área corresponde ao número em uma região ocupada pelo objeto de interesse, por exemplo, uma região suspeita de lesão. É esperado que as imagens segmentadas tenham aproximadamente o mesmo valor numérico de área.

O Perímetro (Per) é o comprimento, em *pixels*, das bordas da região. Apesar de regiões com diferentes formatos possam ter o mesmo perímetro, ela é uma métrica importante para avaliar a similaridade de regiões.

O Fator de Forma (FF) fornece uma comparação entre a área de um polígono com o quadrado do seu perímetro. Em um círculo, o fator de forma é 1, enquanto em um quadrado é  $\frac{\pi}{4}$ . A equação do fator de forma é mostrada na Equação 6.1.

$$\text{FatorDeForma} = \frac{4 \cdot \pi \cdot \text{Área}}{\text{Perímetro}^2}. \quad (6.1)$$

Solidez é uma métrica que especifica a proporção entre os *pixels* de uma área

convexa (área fechada, sem buracos) que também estão na região, de acordo com a Equação 6.2.

$$\text{Solidez} = \frac{\text{Área}}{(\text{ÁreaConvexa})}. \quad (6.2)$$

O valor de Solidez em um polígono convexo, sem buracos, é igual a 1.0, representando um objeto sólido. Quando a solidez é menor do que 1.0 significa que o objeto é irregular ou que contém buracos. Portanto, a solidez ajuda a indicar a forma do objeto.

O Diâmetro de *Feret* é a maior distância entre dois pontos da borda da região, também conhecida como calíper máximo. Neste trabalho, o ângulo do diâmetro de *Feret* é calculado para 0 e 90 graus, o que representa a distância máxima entre as coordenadas  $x$  e  $y$ , chamadas de *Feret X* (FX) e *Feret Y* (FY), respectivamente. É importante notar que as métricas relacionadas à forma devem ser analisadas como um conjunto e não individualmente.

A Área Sobreposta (*Area Overlap Measure*, AOM) é uma das técnicas mais utilizadas no estado da arte para analisar a qualidade da segmentação da lesão. Apesar de ela não refletir a qualidade quanto à forma e contorno da segmentação, ela é utilizada neste trabalho para fins comparativos com trabalhos na encontrados na literatura. A Área Sobreposta é definida pela Equação 6.3

$$\text{AOM} = \frac{\text{Área}(\text{Seg} \cap \text{GT})}{\text{Área}(\text{Seg} \cup \text{GT})}, \quad (6.3)$$

onde Seg representa a imagem segmentada e GT a imagem ouro.

Para métricas como Área, Perímetro, Fator de Forma e Distância de Feret, não existe um intervalo definido de valores, podendo assumir valor mínimo zero e valor máximo dependendo da segmentação obtida. Sendo assim, para poder avaliar melhor os resultados obtidos, foi definido uma medida de erro, para cada métrica, baseada na métrica aplicada para a imagem segmentada e a imagem ouro. O erro de cada métrica é definido pela Equação 6.4.

$$E_{\text{Métrica}} = 1 - \exp\left(-\frac{|\text{Métrica}_{\text{Seg}} - \text{Métrica}_{\text{GT}}|}{\text{Métrica}_{\text{GT}}}\right), \quad (6.4)$$

onde  $\text{Métrica}_{\text{Seg}}$  e  $\text{Métrica}_{\text{GT}}$  são valores de métrica para a imagem segmentada e imagem ouro, respectivamente. Desta forma, a medida  $E_{\text{Métrica}}$  varia entre 0, quando as métricas aplicadas à imagem ouro e à imagem segmentada são iguais, e se aproxima de 1 quando as métricas possuem valores muito distintos.

A métrica de Sensibilidade mede a taxa de reconhecimento de verdadeiros positivos. Neste trabalho, a Sensibilidade é avaliada para a classificação de *pixels*, e é descrita pela Equação 6.5.

$$\text{Sensibilidade} = \frac{|F_{\text{Seg}} \cap F_{\text{GT}}|}{|F_{\text{Seg}} \cap F_{\text{GT}}| + |B_{\text{Seg}} \cap F_{\text{GT}}|}, \quad (6.5)$$

onde  $F_{\text{Seg}}$  e  $F_{\text{GT}}$  são *pixels* do objeto da imagem segmentada e da imagem ouro, respectivamente, enquanto  $B_{\text{Seg}}$  e  $B_{\text{GT}}$  são os *pixels* da imagem segmentada e de fundo, respectivamente.

A Especificidade mede a taxa de verdadeiro negativo, sendo descrita pela Equação 6.6.

$$\text{Especificidade} = \frac{|B_{\text{Seg}} \cap B_{\text{GT}}|}{|B_{\text{Seg}} \cap B_{\text{GT}}| + |F_{\text{Seg}} \cap B_{\text{GT}}|}. \quad (6.6)$$

Uma vez que um alto valor de sensibilidade e especificidade não necessariamente significam uma boa segmentação, a Acurácia Balanceada (*Balanced Accuracy*, BAC) é definida como a média da Sensibilidade e Especificidade, descrevendo ambas as taxas de reconhecimento de verdadeiro positivo e verdadeiro negativo. A métrica de Acurácia Balanceada é descrita na Equação 6.7.

$$\text{BAC} = \frac{\text{Sensibilidade} + \text{Especificidade}}{2}. \quad (6.7)$$

O *Slope Spectrum Pattern* (SSP), proposto por (TOUDJEU et al., 2008), é uma métrica que representa uma imagem através de uma assinatura. Dessa forma, pode-se atribuir uma assinatura a uma imagem segmentada e comparar com a segmentação da imagem ouro. Caso duas imagens tenham Espectro Padrão próximos, elas são consideradas similares. O algoritmo SSP extrai segmentos de aumento de intensidade como Espectro de Padrões. Um segmento de aumento de intensidade é definido como uma variação em termos de valor de intensidade quando varia-se da localização de um *pixel* para outro. Essa variação pode ser descrita como uma função de derivada discreta. No trabalho proposto, o SSP das imagens segmentadas são comparadas com o SSP das imagens ouro para avaliar a similaridade de forma entre elas.

### 6.5.1 Classificador

O classificador é utilizado na metodologia proposta como forma de validar a qualidade de segmentação das técnicas aplicadas para a base de dados IRMA. Uma vez que são extraídos os momentos de Zernike da imagem segmentada, os atributos são utilizados como entrada para o classificador, o qual irá classificar a lesão como da classe benigna ou

maligna. Apesar de ser utilizado um classificador, a classificação não é o foco do trabalho, ela é usada apenas como uma métrica adicional de validação da qualidade das imagens segmentadas. Classificadores como discriminantes lineares e redes neurais artificiais (RNA) têm sido utilizados no diagnóstico de câncer de mama, possuindo boa performance em classificação de lesões (CHENG et al., 2006).

O classificador Perceptron de múltiplas camadas (*MultiLayer Perceptron*, MLP) têm sido um bom classificador para aplicações de imagens de mamografia, conforme usado com sucesso por Tahmasbi, Saki e Shokouhi (2011), estando entre os classificadores de RNA mais utilizados nesse contexto (MUŠTRA; GRGIĆ; DELAČ, 2012; FERNANDES; SANTOS, 2014).

Neste trabalho foi utilizado o classificador MLP, por ser um classificador clássico já validado na literatura. No entanto, outros classificadores, tais como Máquinas de Vetores de Suporte, descrito por Steinwart e Christmann (2008), podem ser utilizados e serão analisados em trabalhos futuros. Como o foco do trabalho não é a classificação, e sim a segmentação, onde a classificação foi utilizada como uma forma adicional de validação do método proposto, foi aplicado o classificador clássico MLP. A configuração da MLP foi definida empiricamente, variando-se a quantidade de neurônios da camada escondida em 10, 20, 30, 40 e 50 neurônios. A configuração com melhores resultados utilizada no trabalho foi a configuração com duas camadas escondidas, cada uma com 30 neurônios, uma camada de entrada com 64 neurônios, e uma camada de saída com dois neurônios. Essa configuração é a mesma utilizada para classificar as imagens segmentadas em todas as técnicas analisadas.

O treinamento da rede foi feito utilizando o algoritmo *Levenberg-Marquardt*, descrito por Wilamowski e Yu (2010), com os parâmetros padrões disponibilizados no *matlab*, com taxa de aprendizado de 0,01. A etapa de treinamento da rede foi realizado com amostras da base, utilizando as informações de entrada e saídas fornecidas pela base. Para o treinamento foi utilizado o método de validação cruzada por *k-folds*, com *k* igual a 10. Os pesos iniciais da rede são definidos aleatoriamente, e para análise dos resultados foi obtida a média de 30 simulações usando validação cruzada 10 *k - fold*.

## 6.6 CONSIDERAÇÕES DO CAPÍTULO

Neste capítulo foi apresentado o fluxo de projeto, composto pelo levantamento bibliográfico, definição de ambiente experimental, construção das imagens ouro, estudos preliminares, desenvolvimento do algoritmo proposto, segmentação das imagens, classificação e análise dos resultados. Também foi descrito o fluxo de simulação para análise de segmentação e classificação utilizadas para as bases Mini-MIAS e IRMA. O fluxo de simulação de realizado para a segmentação da imagem de mamografia é iniciado a partir da região de interesse inicial, onde é aplicado o método de segmentação. A análise de

segmentação baseia-se no uso de métricas de similaridade quanto à forma das imagens segmentadas e a imagem ouro. Para a base IRMA foi utilizado um classificador para realizar a classificação em benigno ou maligno baseado nos atributos extraídos utilizando momentos de Zernike. O algoritmo proposto é comparado com técnicas semi-supervisionadas do estado da arte utilizando a metodologia descrita.

## 7 RESULTADOS E DISCUSSÃO

Este capítulo tem como objetivo apresentar os resultados obtidos do método proposto para segmentação de lesões em imagens de mamografia digital. Neste capítulo é apresentada a análise comparativa com técnicas do estado da arte, mostrando o desempenho de cada técnica para as métricas utilizadas, aplicados para as bases Mini-MIAS e IRMA.

### 7.1 INTRODUÇÃO

Este capítulo encontra-se dividido em três partes: a primeira parte mostra os resultados da análise dos parâmetros do algoritmo proposto, a segunda parte mostra os resultados da técnica proposta e técnicas do estado da arte para a base Mini-MIAS, e a terceira parte mostra os resultados de segmentação para a base de dados IRMA.

### 7.2 ANÁLISE DE PARÂMETROS DO ALGORITMO PROPOSTO

Esta seção mostra os resultados da análise de parâmetros do algoritmo proposto *Fuzzy* GrowCut (FGC) e os resultados obtidos. O algoritmo proposto, em sua configuração, consta com dois parâmetros que podem ser ajustados de acordo com a especificidade do problema. Estes parâmetros são o número de sementes iniciais e a largura da função Gaussiana. Para realizar a seleção dos melhores parâmetros foi realizada uma análise com variação do número de sementes, de 5 a 40, com aumento de 5 sementes entre um parâmetro e outro, e largura da região Gaussiana, com valor de  $\alpha$  entre 2 e 12, aumentando duas unidades entre um parâmetro e outro. As análises foram realizadas para todas as imagens com lesão da base de dados Mini-MIAS, analisando as métricas relacionadas ao formato da segmentação, descritas no capítulo 6. A análise foi realizada utilizando o seletor automático de sementes com o algoritmo Evolução Diferencial. A Tabela 21 mostra os resultados da variação de parâmetros usando Evolução Diferencial.

Na Tabela 21, a coluna representada por  $NS$  é o número de sementes, a coluna  $G$  é o parâmetro de largura da região Gaussiana, as colunas  $E_{\text{Área}}$ ,  $E_{\text{FF}}$ ,  $E_{\text{Per}}$ ,  $E_{\text{FX}}$ ,  $E_{\text{FY}}$  e  $E_{\text{Solidez}}$  são as medidas de erro para as métricas de Área, Fator de Forma, Perímetro, Distância de *Feret* no eixo  $x$  e  $y$ , e Solidez, respectivamente. Para essas métricas, quanto menor o valor melhor a segmentação. A coluna AOM representa a Área Sobreposta, seguido da coluna referente à Acurácia Balanceada (BAC). Para essas métricas, quanto maior o valor melhor a qualidade da segmentação. Os melhores valores de métricas estão representados em negrito. Para a análise realizada, verificou-se que a configuração de parâmetros com melhores resultados foi obtida usando valores de número de sementes igual a 40 e valor de  $\alpha$  igual a 2. Esses parâmetros são utilizados nas análises a seguir.

**Tabela 21** – Análise de Variação de Parâmetros do Algoritmo *Fuzzy GrowCut*, usando Evolução Diferencial.

NS	G	$E_{\text{Área}}$	$E_{\text{FF}}$	$E_{\text{Per}}$	$E_{\text{FX}}$	$E_{\text{FY}}$	AOM	BAC
5	2	0,65±0,18	0,47±0,34	0,59±0,21	0,58±0,21	0,58±0,22	0,08±0,15	0,54±0,08
5	4	0,61±0,22	0,47±0,35	0,55±0,25	0,53±0,25	0,54±0,25	0,13±0,21	0,57±0,11
5	6	0,60±0,22	0,42±0,34	0,52±0,24	0,49±0,26	0,52±0,24	0,17±0,21	0,59±0,12
5	8	0,60±0,22	0,41±0,35	0,49±0,26	0,47±0,27	0,50±0,25	0,20±0,21	0,61±0,13
5	10	0,59±0,23	0,41±0,34	0,48±0,27	0,45±0,28	0,49±0,25	0,23±0,22	0,62±0,13
5	12	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
10	2	0,59±0,20	0,42±0,34	0,51±0,25	0,50±0,24	0,51±0,24	0,18±0,20	0,59±0,11
10	4	0,51±0,24	0,38±0,34	0,41±0,27	0,40±0,28	0,42±0,26	0,28±0,25	0,65±0,14
10	6	0,50±0,25	0,38±0,33	0,39±0,27	0,37±0,27	0,39±0,27	0,34±0,27	0,68±0,16
10	8	0,48±0,29	0,38±0,32	0,36±0,27	0,35±0,27	0,36±0,28	0,37±0,27	0,70±0,17
10	10	0,48±0,32	0,37±0,32	0,37±0,29	0,34±0,29	0,36±0,29	0,39±0,28	0,71±0,17
10	12	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
15	2	0,47±0,23	0,36±0,31	0,35±0,27	0,35±0,26	0,36±0,26	0,35±0,23	0,68±0,13
15	4	0,35±0,26	0,31±0,29	0,29±0,26	0,24±0,25	0,27±0,26	0,49±0,27	0,76±0,16
15	6	0,38±0,31	0,34±0,31	0,32±0,27	0,26±0,25	0,30±0,27	0,50±0,25	0,78±0,16
15	8	0,59±0,30	0,34±0,28	0,40±0,26	0,34±0,24	0,36±0,25	0,41±0,20	0,76±0,14
15	10	0,74±0,27	0,41±0,29	0,45±0,26	0,42±0,23	0,43±0,25	0,33±0,18	0,68±0,14
15	12	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
20	2	0,35±0,23	0,31±0,31	0,28±0,25	0,24±0,25	0,27±0,25	0,48±0,27	0,75±0,15
20	4	0,43±0,31	0,32±0,28	0,34±0,27	0,28±0,24	0,28±0,24	0,50±0,26	0,80±0,15
20	6	0,65±0,32	0,37±0,27	0,43±0,27	0,38±0,24	0,40±0,25	0,38±0,21	0,73±0,16
20	8	0,81±0,24	0,46±0,30	0,48±0,27	0,47±0,25	0,48±0,26	0,28±0,16	0,62±0,13
20	10	0,85±0,23	0,48±0,29	0,47±0,26	0,47±0,25	0,50±0,24	0,25±0,15	0,56±0,09
20	12	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
25	2	0,30±0,24	0,32±0,29	0,27±0,25	0,22±0,24	0,24±0,24	0,55±0,23	0,80±0,14
25	4	0,52±0,33	0,29±0,25	0,36±0,27	0,31±0,23	0,33±0,25	0,47±0,24	0,80±0,15
25	6	0,81±0,24	0,43±0,28	0,47±0,24	0,44±0,25	0,46±0,23	0,28±0,17	0,61±0,12
25	8	0,88±0,17	0,48±0,28	0,47±0,25	0,47±0,25	0,50±0,23	0,25±0,14	0,56±0,08
25	10	0,90±0,15	0,49±0,27	0,48±0,24	0,48±0,23	0,50±0,23	0,24±0,13	0,54±0,06
25	12	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
30	2	<b>0,27±0,23</b>	0,26±0,25	<b>0,24±0,21</b>	0,20±0,19	<b>0,20±0,19</b>	0,57±0,23	0,82±0,13
30	4	0,66±0,31	0,31±0,27	0,43±0,25	0,37±0,25	0,40±0,24	0,41±0,21	0,76±0,13
30	6	0,88±0,18	0,49±0,26	0,48±0,24	0,47±0,24	0,50±0,22	0,26±0,15	0,57±0,09
30	8	0,91±0,14	0,51±0,27	0,48±0,25	0,48±0,24	0,50±0,23	0,24±0,13	0,53±0,05
30	10	0,92±0,13	0,50±0,27	0,48±0,24	0,48±0,24	0,50±0,23	0,24±0,13	0,53±0,04
30	12	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
35	2	0,31±0,26	0,27±0,25	0,27±0,24	0,21±0,19	0,22±0,21	0,58±0,21	0,84±0,12
35	4	0,80±0,24	0,35±0,26	0,46±0,26	0,43±0,24	0,46±0,23	0,32±0,17	0,67±0,12
35	6	0,90±0,15	0,50±0,27	0,47±0,25	0,49±0,24	0,50±0,23	0,24±0,13	0,54±0,06
35	8	0,91±0,14	0,50±0,27	0,48±0,25	0,49±0,24	0,50±0,23	0,24±0,13	0,53±0,05
35	10	0,92±0,13	0,50±0,27	0,48±0,25	0,49±0,24	0,50±0,23	0,24±0,13	0,53±0,04
35	12	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
40	2	0,30±0,27	<b>0,26±0,22</b>	0,25±0,22	<b>0,20±0,18</b>	0,21±0,18	<b>0,60±0,22</b>	<b>0,86±0,11</b>
40	4	0,85±0,21	0,43±0,26	0,48±0,25	0,46±0,24	0,49±0,22	0,28±0,15	0,62±0,11
40	6	0,91±0,13	0,50±0,27	0,48±0,24	0,49±0,24	0,50±0,23	0,24±0,13	0,54±0,05
40	8	0,92±0,13	0,51±0,27	0,48±0,25	0,49±0,24	0,50±0,23	0,24±0,13	0,53±0,05
40	10	0,92±0,13	0,51±0,27	0,48±0,25	0,49±0,24	0,50±0,23	0,24±0,13	0,53±0,05
40	12	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00

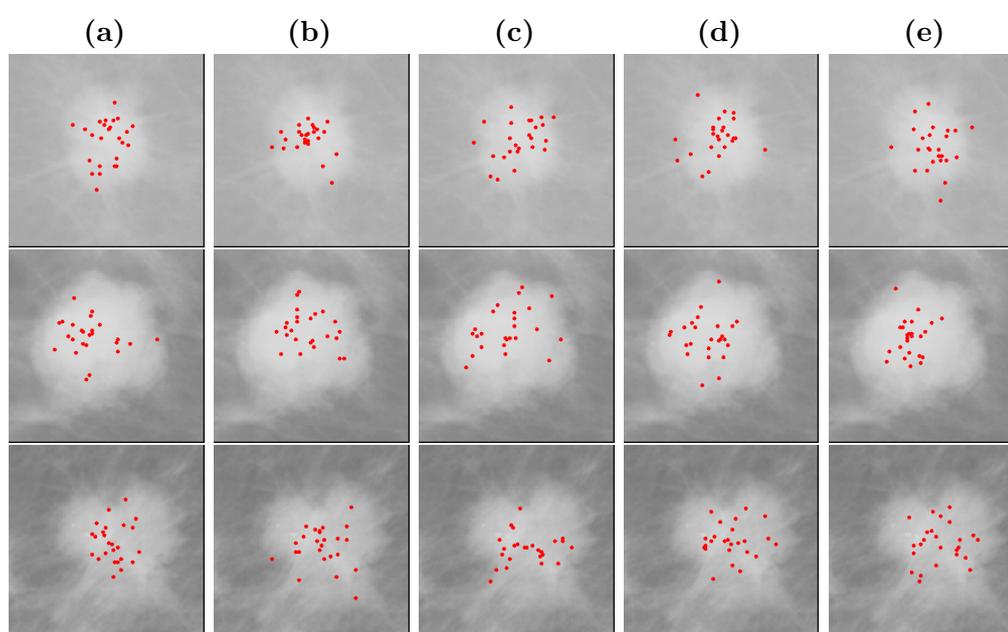
### 7.3 ANÁLISE DE CONVERGÊNCIA

Foi realizada a análise de convergência das sementes para verificar se as soluções encontradas pela técnica Evolução Diferencial convergiam para a mesma região em diferentes simulações. Para isso, foram selecionadas amostras de diferentes tipos de lesões: circunscrito, espiculado e indistinto. Para cada tipo foram selecionadas 4 amostras, onde

para cada uma foram realizadas 30 simulações usando Evolução Diferencial.

A Figura 80 mostra as sementes geradas ao longo de diferentes simulações. Cada linha da Figura 80 representa uma imagem de lesão diferente, enquanto as colunas mostram as sementes geradas em simulações independentes. Cada semente gerada é representada como um ponto vermelho na imagem. O objetivo da Figura 80 é mostrar que as sementes convergem para a mesma região caso o processo de geração de sementes seja repetido. Tanto o centro de massa quanto o desvio padrão dos pontos possuem pouca variação. A análise em relação ao centro de massa e variância é mostrada na Figura 82.

**Figura 80** – Sementes geradas em diferentes simulações.



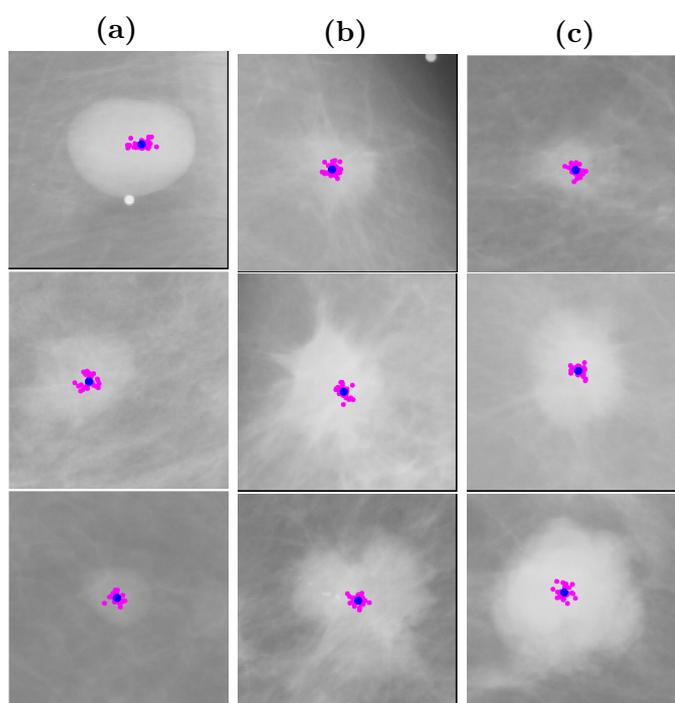
Fonte: do autor.

A Figura 82 mostra a análise convergência para 3 lesões do tipo circunscrito, na coluna *a*, 3 do tipo espiculado, na coluna *b*, e 3 do tipo indistinto, na coluna *c*. Cada ponto rosa representa o centro de massa encontrado em cada uma das 30 simulações. O ponto azul representa o centro de massa médio das 30 simulações. Desta forma, pode-se observar que o algoritmo converge para todos os casos analisados, com o centro de massa localizado dentro da lesão. Esta premissa é utilizada para as próximas análises, onde será utilizada apenas uma única execução do algoritmo Evolução Diferencial para realizar a segmentação.

### 7.3.1 Análise de Tolerância a Falhas

O GrowCut clássico, assim como a maioria das técnicas baseadas em sementes, é bastante sensível quanto à localização das sementes iniciais. Normalmente, um posicionamento incorreto de uma semente inicial por um especialista poderá impactar na

**Figura 82** – Análise de convergência do modelo de geração automática de sementes.



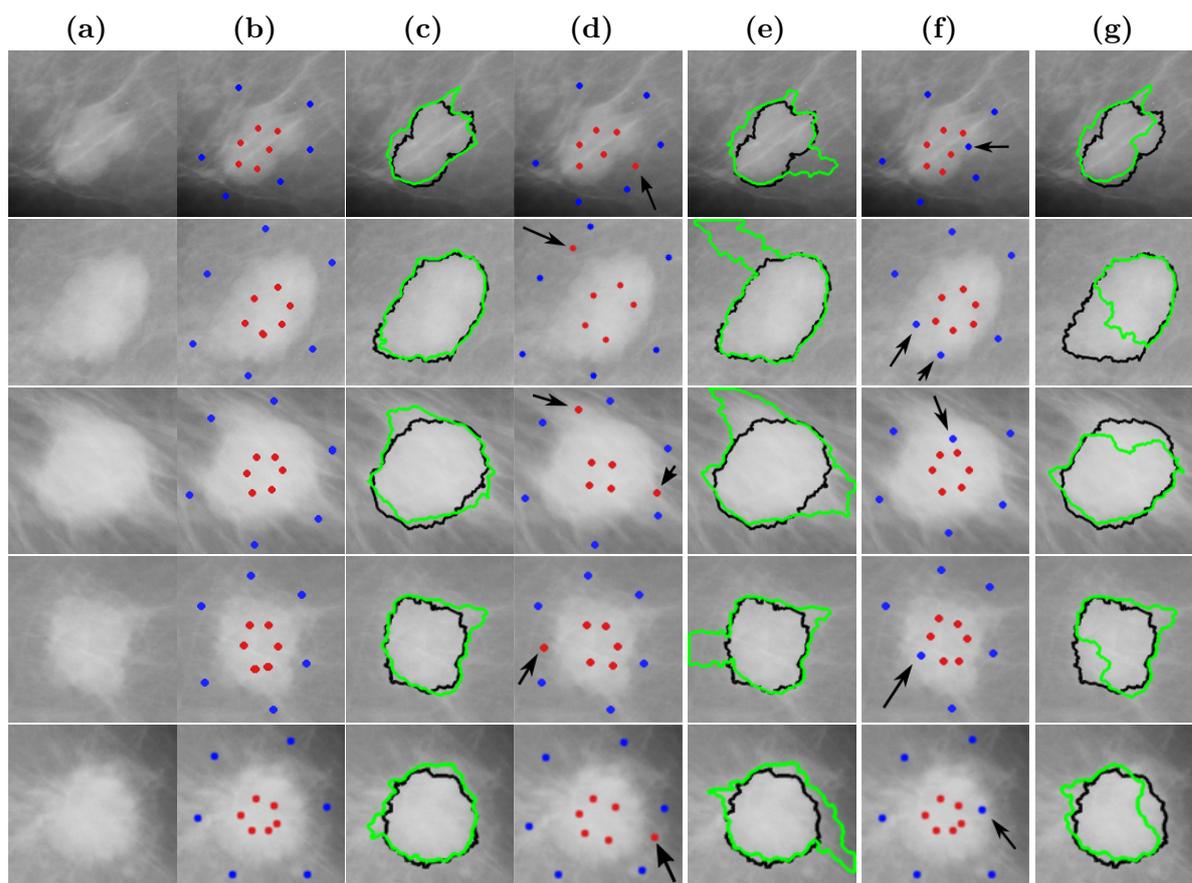
Fonte: do autor.

qualidade da segmentação. Isso não é desejado em um método supervisionado, uma vez que a etapa supervisionada está sujeita a falhas humanas. Para esta análise, foi realizada a comparação da segmentação do GrowCut, em um primeiro cenário, com as sementes posicionadas corretamente e um segundo cenário, com um deslocamento de umas das sementes, posicionada incorretamente. A Figura 84 mostra como a localização das sementes no GrowCut clássico influencia na segmentação final.

Na Figura 84, a coluna *a* mostra a ROI original, a coluna *b* e *c* mostram a localização das sementes iniciais posicionadas corretamente e a segmentação obtida, respectivamente. Os pontos em vermelho são as sementes rotuladas como pertencentes à região da lesão e as azuis fora da lesão. A coluna *d* mostra o posicionamento das sementes iniciais, mas com uma semente da classe de lesão posicionada incorretamente fora da região de lesão. A seta preta em cada figura mostra a semente que está posicionada incorretamente. A coluna *e* mostra a segmentação obtida com as sementes da coluna *d*. A coluna *f* mostra a seleção das sementes, porém com uma semente de não-lesão posicionada incorretamente, conforme indicada pela seta preta. Por fim, a coluna *g* mostra a segmentação obtida a partir das sementes da coluna *f*.

A partir da Figura 84 pode-se observar que um pequeno posicionamento incorreto das sementes pode resultar em uma segmentação imprecisa. Desta forma, o GrowCut não pode ser considerado tolerante à falhas em relação a seleção de sementes. No método

**Figura 84** – Análise de tolerância à falhas do posicionamento das sementes iniciais no GrowCut clássico. (a) ROI original; (b) Sementes selecionadas corretamente; (c) Segmentação obtida com as sementes da coluna (b); (d) Sementes selecionadas com um posicionamento incorreto da semente interna; (e) Segmentação obtida com as sementes da coluna (d); (f) Sementes selecionadas com um posicionamento incorreto da semente externa; (g) Segmentação obtida com as sementes da coluna (d).

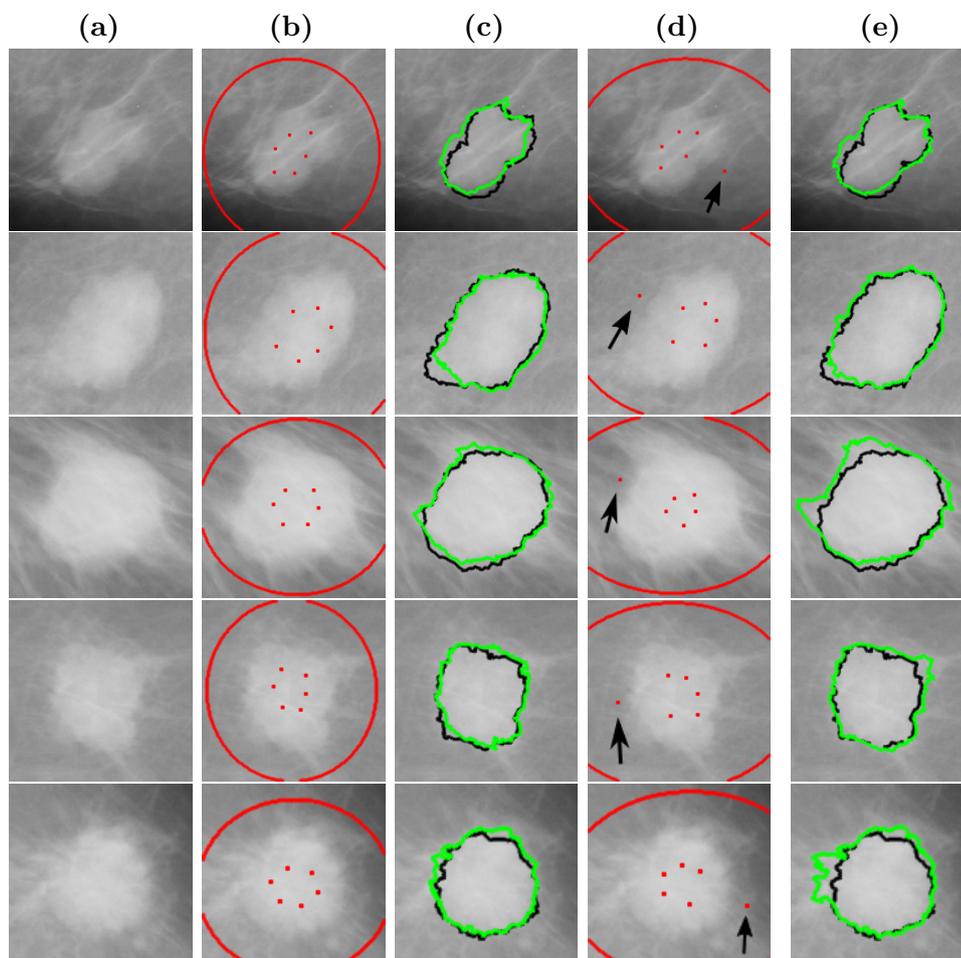


Fonte: do autor.

proposto *Fuzzy* GrowCut, foi removida a necessidade de seleção de sementes da classe de não-lesão, além de o algoritmo ser baseado no centro de massa e desvio padrão das sementes, o que reduz a sensibilidade do algoritmo e melhora sua tolerância à falhas. A Figura 86 mostra a análise da localização das sementes e segmentação obtida para o método proposto.

A coluna *a* da Figura 86 mostra a ROI original, a coluna *b* mostra as sementes iniciais selecionadas pelo usuário e a região gaussiana gerada através do método proposto. A coluna *c* mostra a segmentação obtida usando as sementes apresentadas na coluna *b*. A coluna *d* mostra a localização das sementes, com uma das sementes localizadas incorretamente, representada pela seta preta, enquanto que a segmentação obtida usando essas sementes é mostrada na coluna *d*. A ROI usada nessa análise é a mesma usada na

**Figura 86** – Análise de tolerância à falhas da localização das sementes iniciais para o GrowCut Fuzzy. (a) ROI original; (b) Sementes geradas corretamente; (c) Segmentação obtida com as sementes da coluna (b); (d) Sementes geradas com uma semente posicionada incorretamente; (e) Segmentação obtida com as sementes da coluna (d).



Fonte: do autor.

Figura 84 e pode ser verificado pela Figura 86 que o *Fuzzy* GrowCut é mais tolerante à falhas em relação pequenas variações na localização das sementes, causando pequenas variações na segmentação final. A segmentação ainda sofre algumas variações, pois o desvio padrão dos pontos é alterado, o que interfere no tamanho e formato da região *fuzzy* gaussiana. Como pode ser observado comparando as colunas *c* e *e* da Figura 86, houve pequeno impacto na segmentação final quando a posição das sementes tiveram pequenas alterações.

A diferença entre os resultados do GrowCut clássico é que nele há pouca flexibilidade na marcação inicial das sementes para se obter uma boa segmentação, exigindo maior esforço especialista para o posicionamento correto das sementes. No *Fuzzy* GrowCut, há uma maior tolerância quanto ao posicionamento incorreto de sementes, de forma que o

posicionamento errado ainda permite que o algoritmo obtenha a segmentação próxima da segmentação com a marcação exata. No entanto, se usuário marcar um grande número de sementes incorretamente, de forma que o centróide fique localizado fora da lesão, o *Fuzzy GrowCut* pode não realizar a segmentação de forma correta.

#### 7.4 RESULTADOS PARA A BASE DE DADOS MINI-MIAS

Os resultados apresentados nessa seção foram analisados para todas as imagens com lesão da base de dados Mini-MIAS, o que corresponde a 57 imagens divididas em circunscrito, espiculado e com bordas indefinidas. A análise foi comparada com as técnicas BEMD, BMCS, MCW, Abordagem Topográfica e WAGA. Os resultados de cada técnica foram avaliados através das métricas descritas no capítulo 6.

Foi realizada a otimização dos parâmetros para cada técnica comparada do estado da arte através de uma busca exaustiva, variando os parâmetros de cada técnica e identificando os valores com melhores resultados. Os melhores parâmetros encontrados para as técnicas BEMD, MCW e Abordagem Topográfica são descritos na Tabela 22. Os resultados para os diferentes parâmetros também são mostrados no Anexo A. Os algoritmos BMCS e WAGA não possuem parâmetros.

**Tabela 22** – Melhores parâmetros para os algoritmos BEMD, MCW e Abordagem Topográfica.

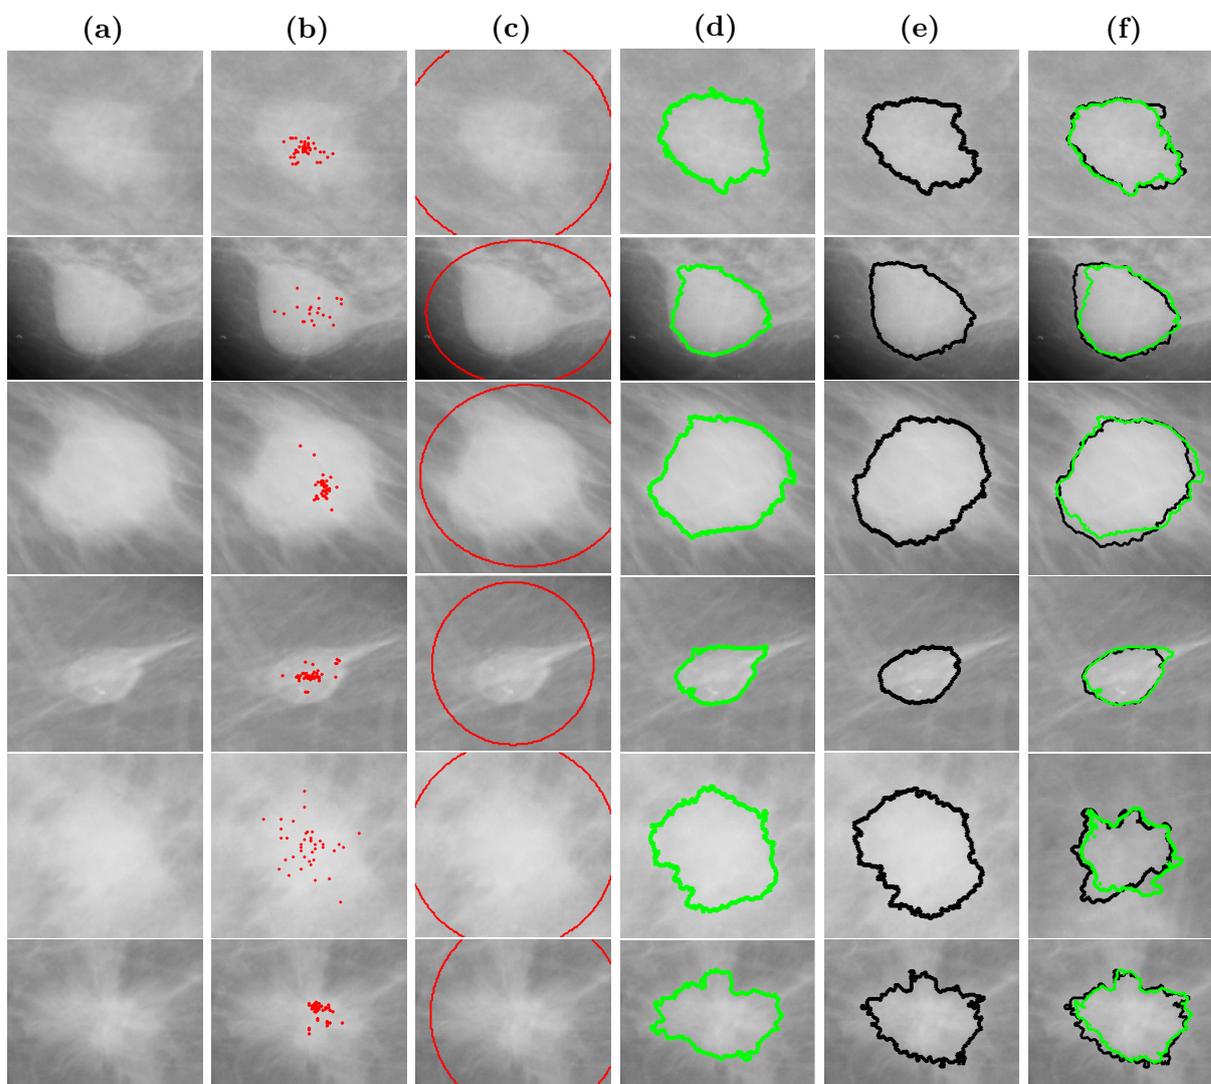
Técnica	Melhores Parâmetros
BEMD	$r_i = 0.4$
MCW	$size_{se} = 7; type_{se} = square$
Topográfica	$n_{levels} = 10; depth = 2$

A Figura 88 mostra o resultados de cada etapa da metodologia proposta, para o algoritmo proposto, para 6 imagens da base de dados Mini-MIAS.

A coluna *a* da Figura 88 representa a região de interesse manualmente selecionada da base de dados. A coluna *b* mostra as sementes obtidas pelo método automático de seleção, usando Evolução Diferencial. Conforme descrito anteriormente, o método proposto necessita de sementes apenas da região de lesão. A coluna *c* ilustra a região *Fuzzy* Gaussiana, onde dentro da região existe maior grau de pertinência dos *pixels* em relação à região de lesão. O tamanho da região gaussiana é baseado na localização das sementes. Por fim, a coluna *d* mostra a segmentação final do método proposto, em verde, comparado com o contorno da imagem ouro, em preto.

A Figura 90 mostra os resultados de segmentação de todas as técnicas analisadas, para as imagens mdb010, mdb021, mdb028, mdb190, mdb132 e mdb312.

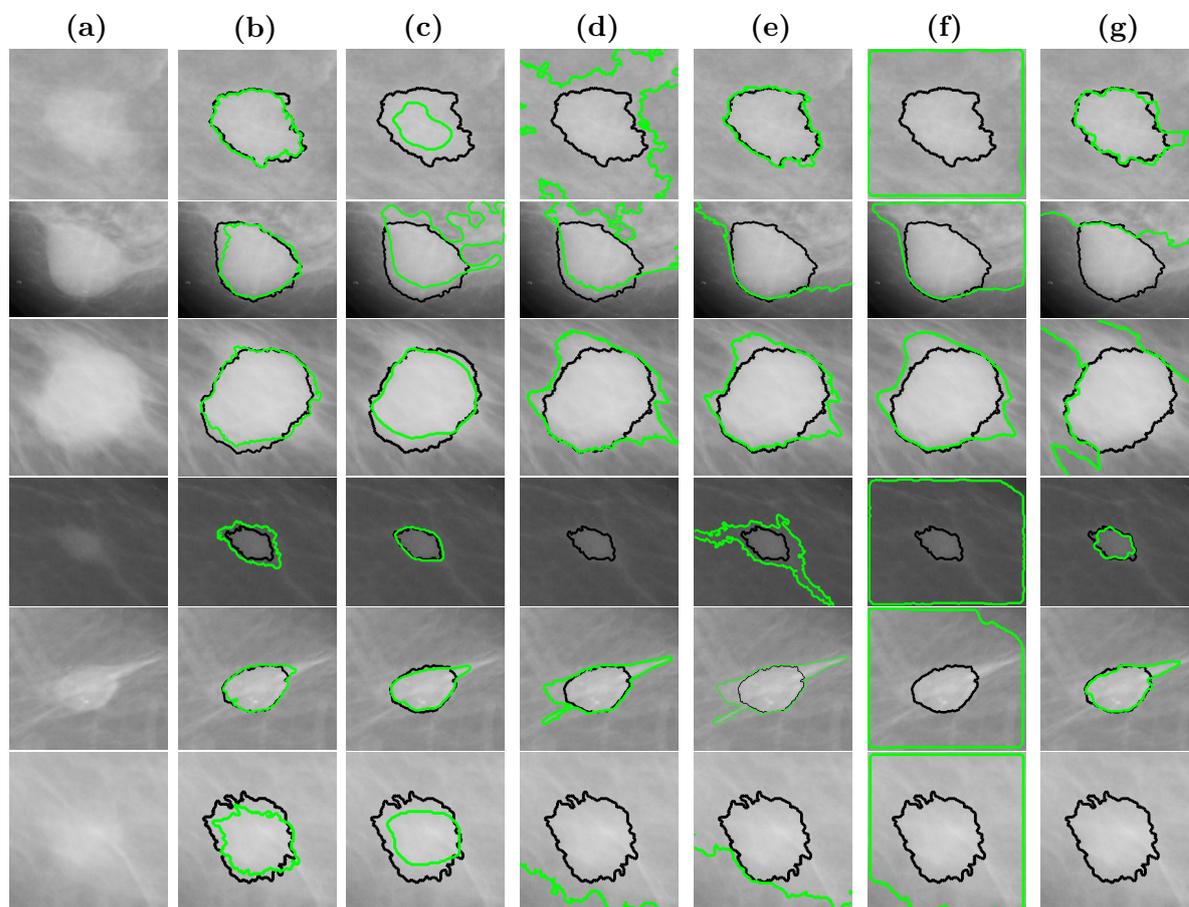
**Figura 88** – Imagens de cada etapa do processo de segmentação do método proposto, para a base Mini-MIAS, para as imagens mdb010, mdb021, mdb028, mdb132, mdb063 e mdb181. (a) Região de Interesse; (b) Sementes geradas aleatoriamente; (c) Região *Fuzzy* Gaussiana; (d) Contorno da segmentação final comparado com a imagem ouro.



Fonte: do autor.

A primeira coluna da Figura 90 é a região de interesse inicial, e as colunas seguintes são as imagens segmentadas das abordagens Topográfica, WAGA, BEMD, BMCS, e MCW, respectivamente. O contorno preto representa o contorno da imagem ouro, enquanto o contorno verde é a segmentação final de cada técnica. A abordagem proposta e a técnica Topográfica obtiveram contorno próximo da imagem ouro para todas as imagens da Figura 90, enquanto que as outras técnicas tiveram maior dificuldade com as imagens mdb312 e mdb021. No entanto, a abordagem proposta obteve melhor segmentação do que a técnica Topográfica para as imagens mdb010 e mdb21, representadas nas duas primeiras linhas. A Figura 90 mostra apenas seis exemplos, mas a análise foi realizada para todas as imagens.

**Figura 90** – Comparação da segmentação das técnicas analisadas, para as imagens mdb010, mdb021, mdb028, mdb190, mdb132 e mdb312. (a) Região de Interesse; (b) *Fuzzy GrowCut*; (c) Topográfico; (d) WAGA; (e) BEMD; (f) BMCS; (g) MCW.



Fonte: do autor.

O valor médio das métricas, para cada técnica analisada, é mostrado na Tabela 23.

Na Tabela 23, os números em negrito representam os melhores valores para cada métrica. Os valores de erro de Área, Fator de Forma, Perímetro, Distância de Ferret no eixo X, Distância de *Ferret* para o eixo Y, e Solidez são representados por  $E_{\text{Área}}$ ,  $E_{\text{FF}}$ ,  $E_{\text{Per}}$ ,  $E_{\text{FX}}$ ,  $E_{\text{FY}}$  e  $E_{\text{Solidez}}$ , respectivamente. Para essas métricas, quanto menor o valor melhor. A Área Sobreposta e a Acurácia Balanceada são representadas como AOM e BAC, respectivamente. Para AOM, Sensibilidade, Especificidade e BAC, quanto maior a métrica melhor a segmentação. Nessa análise também é inserida a versão adaptativa do método proposto: AFGC (*Adaptive Fuzzy GrowCut*).

A partir da Tabela 23 pode ser observado que o FGC obteve menor valor de erro para a maioria das métricas. Isso indica que a segmentação obteve contorno próximo das imagens ouro, em média, pois as métricas de erro indicam menor erro para o FGC. A técnica BEMD obteve alta Sensibilidade, mas baixa Especificidade. Isso quer dizer que a

**Tabela 23** – Média de valores das métricas analisadas, para todos os tipos de lesão da base Mini-MIAS, para as técnicas implementadas.

Métricas	BEMD	BMCS	MCW	FGC	AFGC	Topográfico	WAGA
$E_{\text{Área}}$	0,72±0,29	0,77±0,29	0,48±0,36	<b>0,30±0,27</b>	0,34±0,31	0,37±0,26	0,60±0,29
$E_{\text{FF}}$	0,40±0,27	0,44±0,29	0,33±0,24	<b>0,26±0,22</b>	0,26±0,2	0,45±0,27	0,36±0,20
$E_{\text{Per}}$	0,63±0,29	0,43±0,26	0,35±0,24	<b>0,25±0,22</b>	0,27±0,2	0,33±0,23	0,53±0,27
$E_{\text{FX}}$	0,47±0,27	0,44±0,26	0,31±0,22	<b>0,20±0,18</b>	0,20±0,21	0,24±0,18	0,37±0,23
$E_{\text{FY}}$	0,47±0,27	0,44±0,26	0,30±0,21	0,21±0,18	<b>0,20±0,21</b>	0,26±0,23	0,37±0,22
$E_{\text{Solidez}}$	0,18±0,25	0,11±0,10	0,11±0,12	<b>0,08±0,07</b>	0,09±0,15	0,11±0,15	0,14±0,13
AOM	0,38±0,24	0,35±0,24	0,43±0,24	<b>0,60±0,22</b>	0,58±0,24	0,51±0,22	0,42±0,25
Sensibilidade	0,91±0,26	<b>0,98±0,05</b>	0,75±0,26	0,81±0,19	0,82±0,22	0,70±0,22	0,83±0,31
Especificidade	0,59±0,22	0,39±0,27	0,66±0,35	<b>0,90±0,09</b>	0,84±0,18	0,88±0,14	0,64±0,34
BAC	0,75±0,12	0,69±0,13	0,71±0,16	<b>0,86±0,11</b>	0,83±0,13	0,79±0,11	0,73±0,16

maioria dos *pixels* foram classificados como lesão, resultando em muitos falsos positivos. O FGC obteve uma alta Especificidade, o que significa uma alta taxa de verdadeiro negativo, e ainda obteve uma alta Acurácia Balanceada. A versão adaptativa, AFGC, apesar de ter tido desempenho inferior ao FGC, apresentou erros menores do que as técnicas do estado da arte, com a vantagem de ausência de configuração de parâmetros. O *boxplot* de cada métrica para os resultados apresentados é mostrado na Figura 93 e Figura 93.

A partir da Figura 93 e Figura 93 pode ser visto que o FGC e AFGC obtiveram menor erro médio, com menor mediana e com menor intervalo, para a maioria das métricas baseadas em erro. Com relação às métricas AOM, Sensibilidade, Especificidade e BAC, as abordagens propostas estiveram entre as melhores técnicas, com valores melhores para AOM e Especificidade.

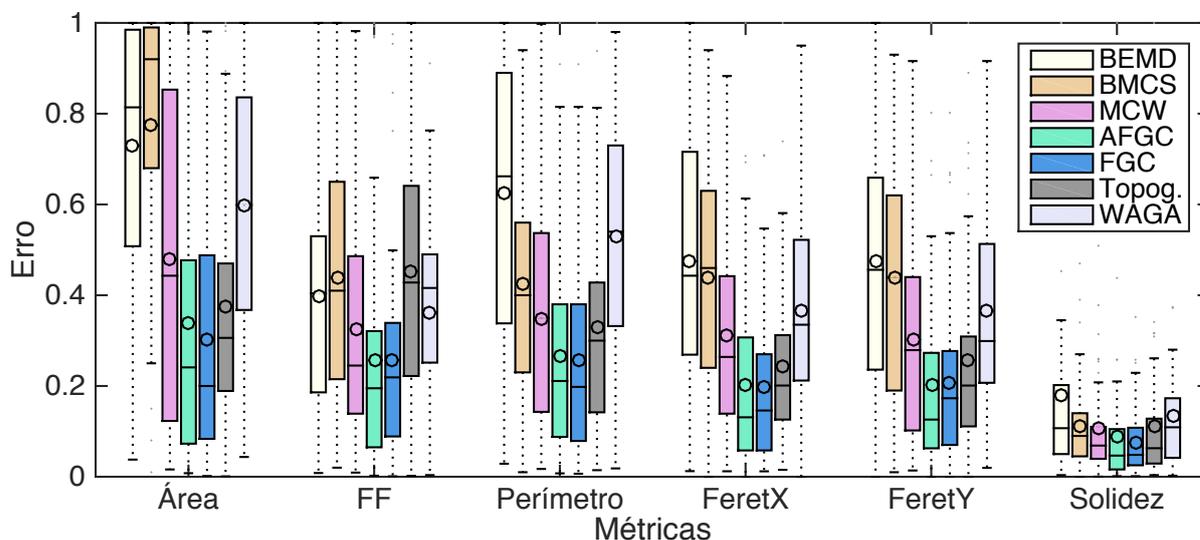
Para diferenciar os resultados do método proposto dos métodos do estado da arte, foi aplicado o teste de hipótese de sinal ranqueado de Wilcoxon (SAMUELS; WITMER; SCHAFFNER, 2012), considerando hipótese nula a igualdade das duas médias, usando índice de confiança de 95%. Resultados são mostrados na Tabela 24.

**Tabela 24** – Valor do P-value do teste de sinal ranqueado de Wilcoxon, quando comparado os resultados do método *Fuzzy* GrowCut proposto com as técnicas analisadas.

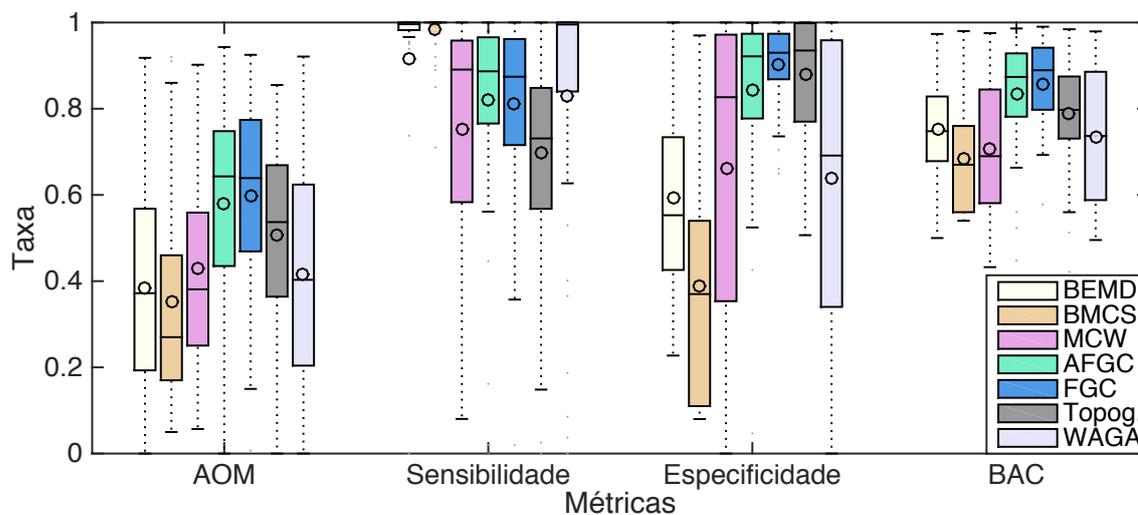
Comparação	$E_{\text{Área}}$	$E_{\text{FF}}$	$E_{\text{Per}}$	$E_{\text{FX}}$	$E_{\text{FY}}$	$E_{\text{Solidez}}$	AOM	BAC
Topográfico	1,37e-01	<b>5,91e-05</b>	<b>4,97e-02</b>	<b>2,86e-02</b>	<b>6,29e-02</b>	<b>8,33e-02</b>	<b>5,16e-03</b>	<b>3,59e-03</b>
WAGA	<b>1,69e-05</b>	<b>5,76e-03</b>	<b>1,95e-07</b>	<b>1,88e-05</b>	<b>5,82e-06</b>	<b>3,24e-03</b>	<b>6,32e-05</b>	<b>5,73e-04</b>
BEMD	<b>1,94e-09</b>	<b>2,57e-04</b>	<b>1,85e-09</b>	<b>5,37e-08</b>	<b>2,99e-08</b>	<b>5,09e-04</b>	<b>2,99e-06</b>	<b>8,82e-05</b>
BMCS	<b>1,89e-09</b>	<b>8,53e-05</b>	<b>4,64e-06</b>	<b>2,57e-07</b>	<b>1,83e-07</b>	<b>9,90e-04</b>	<b>2,99e-06</b>	<b>5,40e-06</b>
MCW	<b>2,28e-02</b>	6,47e-02	<b>4,08e-03</b>	<b>3,64e-04</b>	<b>7,97e-04</b>	1,63e-01	<b>4,91e-05</b>	<b>2,61e-06</b>

Na Tabela 24, valores abaixo de 0,05 são interpretados como rejeição à hipótese nula, isto é, indica que as populações são diferentes, com nível de confiança de 95%. Os valores em negrito na Tabela 24 mostram a rejeição a hipótese nula, indicando que para o algoritmo daquela linha e para aquela métrica, os resultados foram estatisticamente diferentes. Consequentemente, a Tabela 24 mostra que o algoritmo proposto FGC obteve

**Figura 92** – Valores médios para as métricas AOM, Sensibilidade, Especificidade e BAC, comparando as técnicas propostas com o estado arte, para todos os tipos de lesão.



**Figura 93** – Valores médios para as métricas de Área, FF, Perímetro, FeretX, FeretY e Solidez, comparando as técnicas propostas com o estado arte, para todos os tipos de lesão.



Fonte: do autor.

melhores resultados para a maioria das métricas, sendo estatisticamente diferente dos outros métodos do estado da arte, com a média de resultados melhor, conforme mostrado na Tabela 23. Os resultados devem ser analisados juntos, uma vez que um resultado isolado para uma dessas métricas não é necessariamente associado à um bom desempenho de segmentação, e sim analisamos o conjunto de todas as métricas.

Foi feita a análise para a métrica *Slope Spectrum Pattern*, utilizando o teste de Wilcoxon para comparar as distribuições obtidas entre imagem segmentada e imagem ouro. Foi utilizado nível de confiança 95% e hipótese nula a igualdade entre as distribuições. A

Tabela 25 mostra os resultados dessa análise. O número de resultados obtidos

**Tabela 25** – Teste Ranqueado de Wilcoxon aplicado para imagens segmentadas e imagens ouro, comparado a distribuição da métrica *Slope Spectrum Pattern*, para todas as técnicas FGC, Topográfico, WAGA, BEMD, BMCS e MCW.

Técnicas	$p$ -value médio	Desvio Padrão	#Hipóteses Nulas Rejeitadas	#Hipóteses Nulas Não Rejeitadas
<i>Fuzzy</i> GrowCut	0,2779	0,2955	21	36
Topográfico	0,1241	0,2323	41	17
WAGA	0,1370	0,2593	38	19
BEMD	0,1022	0,2280	42	15
BMCS	0,1380	0,2350	32	25
MCW	0,2299	0,3054	28	29

A Tabela 25 indica o valor médio de  $p$ -value, o desvio padrão, o número de hipóteses nula rejeitadas e o número de hipóteses não rejeitadas. Pode-se observar que o método proposto *Fuzzy* GrowCut apresentou o menor número de hipóteses rejeitadas, indicando um maior número de imagens próximas à imagem ouro, quando comparado com técnicas do estado da arte.

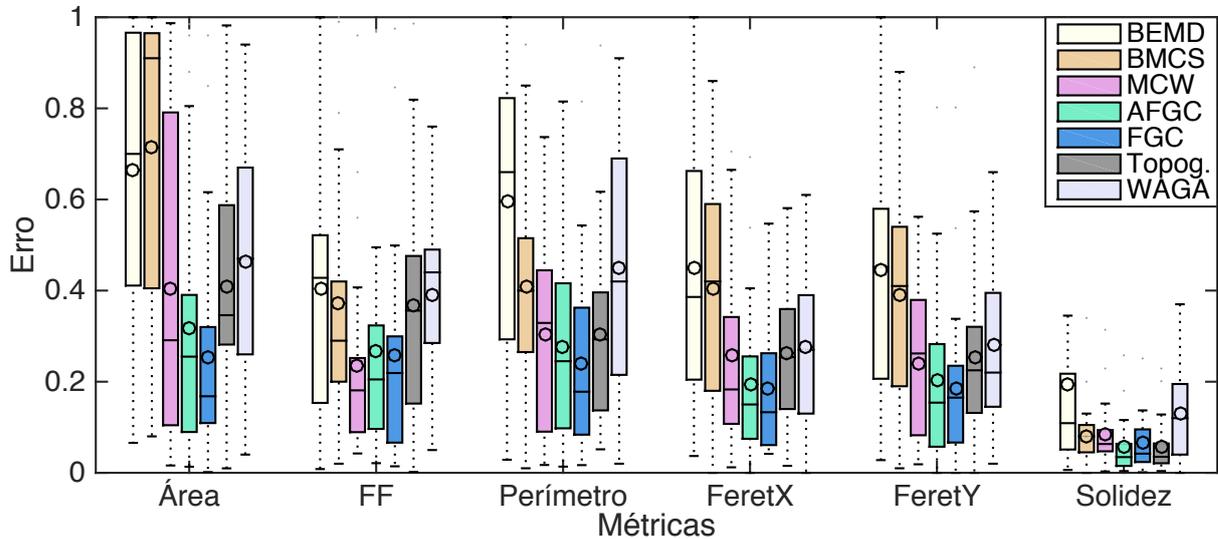
Os resultados também foram analisados para cada tipo de lesão separadamente, a fim de identificar que tipo de lesão cada técnica obteve melhores resultados. A Tabela 26 mostra a média de resultados para imagens circunscritas da base analisada. Os valores em negrito mostra os melhor valor encontrado para cada métrica.

**Tabela 26** – Média de valores das métricas para as técnicas analisadas, para lesões do tipo circunscrito.

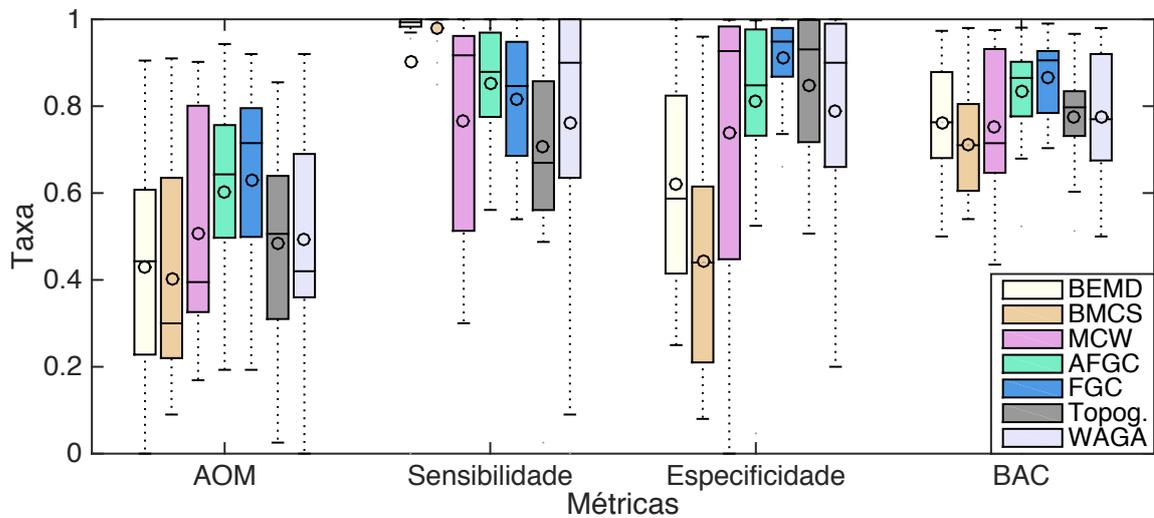
Métricas	BEMD	BMCS	MCW	FGC	AFGC	Topográfico	WAGA
$E_{\text{Área}}$	0,67±0,31	0,71±0,32	0,41±0,35	<b>0,25±0,25</b>	0,32±0,31	0,41±0,27	0,46±0,27
$E_{\text{FF}}$	0,40±0,30	0,37±0,28	<b>0,24±0,23</b>	0,26±0,25	0,27±0,25	0,37±0,25	0,39±0,18
$E_{\text{Per}}$	0,60±0,30	0,41±0,24	0,31±0,22	<b>0,24±0,20</b>	0,28±0,22	0,30±0,21	0,45±0,30
$E_{\text{FX}}$	0,45±0,30	0,40±0,26	0,26±0,20	<b>0,18±0,15</b>	0,20±0,28	0,26±0,17	0,28±0,18
$E_{\text{FY}}$	0,44±0,28	0,39±0,26	0,24±0,17	<b>0,19±0,18</b>	0,20±0,20	0,25±0,20	0,28±0,18
$E_{\text{Solidez}}$	0,19±0,27	0,08±0,07	0,08±0,07	<b>0,06±0,06</b>	<b>0,06±0,06</b>	<b>0,06±0,06</b>	0,13±0,10
AOM	0,43±0,26	0,40±0,25	0,51±0,26	<b>0,63±0,20</b>	0,60±0,21	0,48±0,21	0,49±0,25
Sensibilidade	0,90±0,29	<b>0,98±0,04</b>	0,77±0,25	0,81±0,16	0,85±0,14	0,70±0,22	0,76±0,32
Especificidade	0,62±0,24	0,44±0,27	0,74±0,31	<b>0,91±0,09</b>	0,81±0,22	0,85±0,16	0,79±0,25
BAC	0,76±0,13	0,71±0,13	0,75±0,16	<b>0,86±0,09</b>	0,83±0,11	0,78±0,11	0,78±0,14

A partir da Tabela 26 pode ser observado que os menores valores de erro das métricas par lesões do tipo circunscrito foram obtidos com o uso da FGC e AFGC, seguido pela abordagem Topográfica, MCW e WAGA. A partir do *boxplot* da Figura 95 e Figura 95, pode-se observar que a abordagem proposta está entre os menores valores médios de erro e desvio padrão para a maioria das métricas.

**Figura 94** – Valores médios para as métricas AOM, Sensibilidade, Especificidade e BAC, comparando as técnicas propostas com o estado arte, para as lesões do tipo circunscrito.



**Figura 95** – Valores médios para as métricas de Área, FF, Perímetro, FeretX, FeretY e Solidez, comparando as técnicas propostas com o estado arte, para as lesões do tipo circunscrito.



Fonte: do autor.

Os resultados da média de valores das métricas para lesões do tipo espiculado é mostrado na Tabela 27.

Como pode ser observado na Tabela 27, os métodos propostos obtiveram melhores resultados para a maioria as métricas relacionadas à forma da segmentação, para lesões do tipo espiculado. Esse resultado mostra que a abordagem proposta é também adequada para segmentar lesões do tipo espiculado, os quais normalmente são difíceis de segmentar devido às suas bordas irregulares. O *boxplot* com os valores das métricas para lesões espiculadas é mostrado na Figura 97 e Figura 97.

**Tabela 27** – Média de valores das métricas para as técnicas analisadas, para lesões do tipo espiculado.

Métricas	BEMD	BMCS	MCW	FGC	AFGC	Topographic	Wavelet
$E_{\text{Área}}$	0,83±0,23	0,84±0,23	0,58±0,37	<b>0,36±0,30</b>	0,38±0,36	0,45±0,27	0,72±0,25
$E_{\text{FF}}$	0,46±0,24	0,44±0,32	0,47±0,25	0,31±0,24	<b>0,30±0,30</b>	0,53±0,30	0,38±0,22
$E_{\text{Per}}$	0,71±0,27	0,51±0,27	0,48±0,24	<b>0,31±0,25</b>	0,33±0,31	0,40±0,30	0,64±0,23
$E_{\text{FX}}$	0,55±0,27	0,51±0,26	0,42±0,23	<b>0,21±0,22</b>	0,25±0,28	0,29±0,23	0,47±0,24
$E_{\text{FY}}$	0,53±0,28	0,50±0,27	0,39±0,26	0,24±0,22	<b>0,23±0,28</b>	0,33±0,29	0,46±0,26
$E_{\text{Solidez}}$	0,20±0,22	0,14±0,12	0,16±0,15	<b>0,10±0,09</b>	0,15±0,23	0,17±0,22	0,18±0,18
AOM	0,30±0,21	0,29±0,21	0,30±0,19	0,52±0,25	<b>0,53±0,29</b>	0,45±0,23	0,32±0,22
Sensibilidade	0,92±0,23	<b>0,98±0,07</b>	0,71±0,29	0,79±0,25	0,77±0,30	0,69±0,27	0,83±0,33
Especificidade	0,54±0,20	0,37±0,25	0,55±0,39	<b>0,88±0,09</b>	0,86±0,14	0,87±0,13	0,56±0,34
BAC	0,73±0,11	0,67±0,12	0,63±0,15	<b>0,83±0,15</b>	0,81±0,17	0,78±0,14	0,69±0,15

Baseado na Figura 97 e Figura 97, pode-se observar que os métodos propostos obtiveram menor média de erros, com um menor desvio padrão. Para as métricas AOM e Acurácia Balanceada, o FGC e AFGC mostrou um melhor desempenho comparado às outras técnicas.

A média de resultados das métricas para lesões do tipo indistinto é apresentado na Tabela 28.

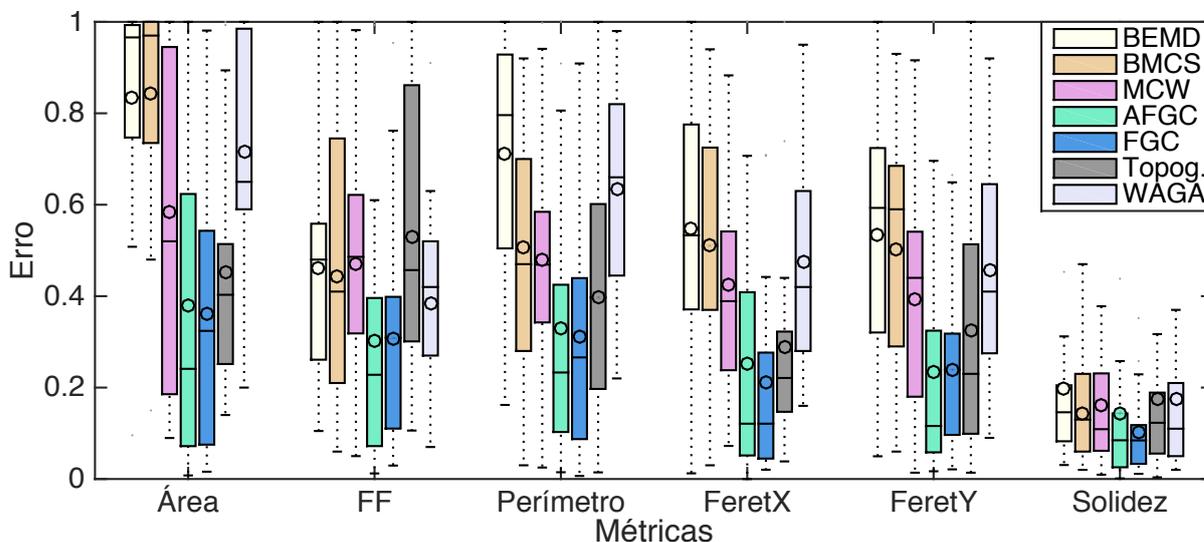
**Tabela 28** – Valor médio das métricas para as técnicas analisadas, para lesões do tipo indefinido.

Métricas	BEMD	BMCS	MCW	FGC	AFGC	Topográfico	WAGA
$E_{\text{Área}}$	0,69±0,31	0,78±0,31	0,45±0,35	0,31±0,24	0,32±0,25	<b>0,23±0,16</b>	0,66±0,28
$E_{\text{FF}}$	0,32±0,24	0,53±0,23	0,29±0,14	<b>0,19±0,14</b>	0,19±0,18	0,49±0,24	0,28±0,17
$E_{\text{Per}}$	0,57±0,31	0,35±0,25	0,25±0,19	0,20±0,18	<b>0,17±0,16</b>	0,28±0,15	0,51±0,23
$E_{\text{FX}}$	0,42±0,30	0,40±0,27	0,25±0,21	0,19±0,16	<b>0,15±0,11</b>	0,16±0,10	0,36±0,25
$E_{\text{FY}}$	0,45±0,26	0,43±0,24	0,28±0,18	0,20±0,17	<b>0,16±0,13</b>	0,17±0,14	0,38±0,20
$E_{\text{Solidez}}$	0,13±0,25	0,12±0,10	0,08±0,12	<b>0,06±0,04</b>	0,07±0,06	0,11±0,10	0,09±0,05
AOM	0,42±0,26	0,35±0,25	0,47±0,22	<b>0,64±0,17</b>	0,62±0,20	0,61±0,19	0,42±0,25
Sensibilidade	0,92±0,26	<b>0,99±0,02</b>	0,79±0,25	0,84±0,14	0,83±0,21	0,70±0,17	0,93±0,25
Especificidade	0,62±0,22	0,33±0,31	0,70±0,33	0,92±0,09	0,88±0,17	<b>0,95±0,08</b>	0,50±0,38
BAC	0,77±0,12	0,66±0,15	0,74±0,14	<b>0,88±0,08</b>	0,86±0,11	0,82±0,09	0,72±0,19

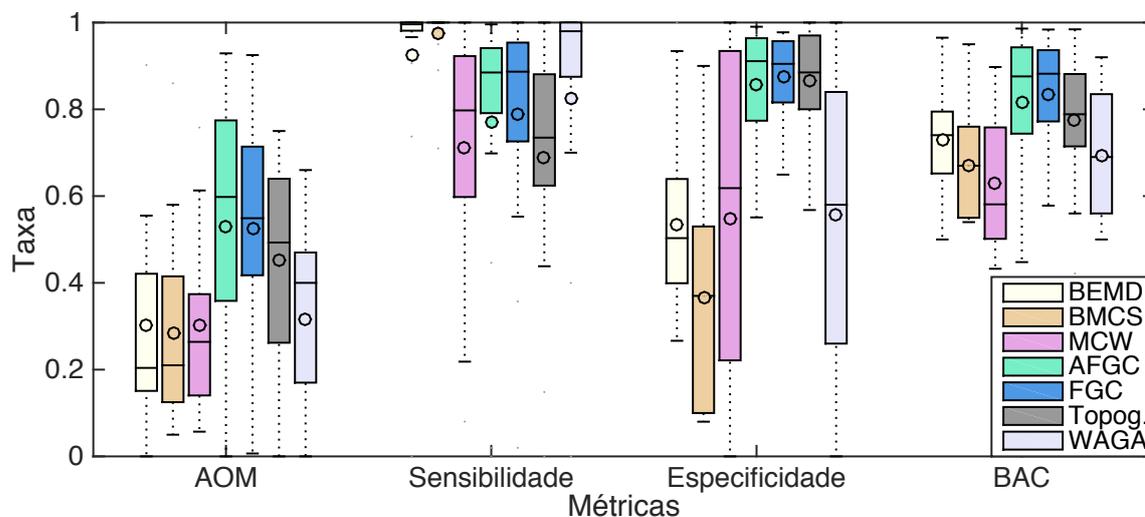
Conforme apresentado na Tabela 28, os métodos FGC e AFGC obtiveram melhores resultados para a maioria das métricas, incluindo fator de forma, AOM e BAC. Para as outras métricas o FGC e AFGC obtiveram valores próximos das técnicas comparadas. Isso indica que a técnica é também adequada para lesões do tipo indefinida, com algumas características de forma mais próximas da imagem ouro, conforme indicado pelo fator de forma e Solidez. O *boxplot* das métricas para os tipos de lesão indistinta é apresentado na Figura 99 e Figura 99.

A abordagem FGC e AFGC foi comparada com cinco técnicas do estado da arte e ela mostrou-se adequada para segmentação quando analisada, utilizando a base de dados Mini-MIAS. Em geral, a técnica FGC e sua versão adaptativa apresentara melhores resultados para a maioria das métricas analisadas, para imagens do tipo circunscrito,

**Figura 96** – Valores médios para as métricas AOM, Sensibilidade, Especificidade e BAC, comparando as técnicas propostas com o estado arte, para as lesões do tipo espiculado.



**Figura 97** – Valores médios para as métricas de Área, FF, Perímetro, FeretX, FeretY e Solidez, comparando as técnicas propostas com o estado arte, para as lesões do tipo espiculado.



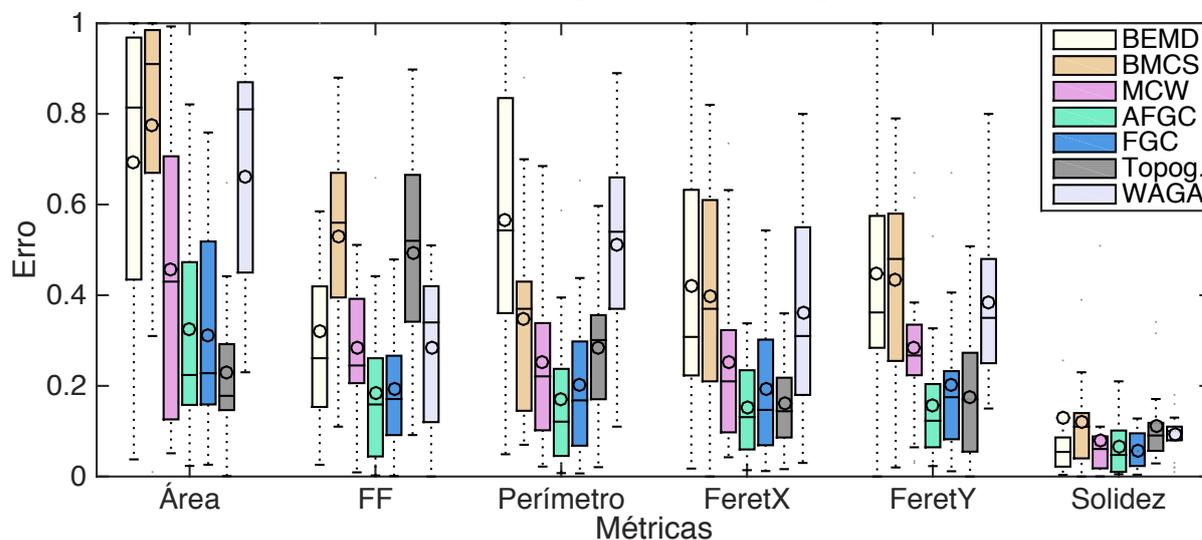
Fonte: do autor.

espiculado e indefinido. No entanto, a técnica FGC obteve maior destaque para segmentar imagens do tipo espiculado, as quais geralmente são mais difíceis de segmentar.

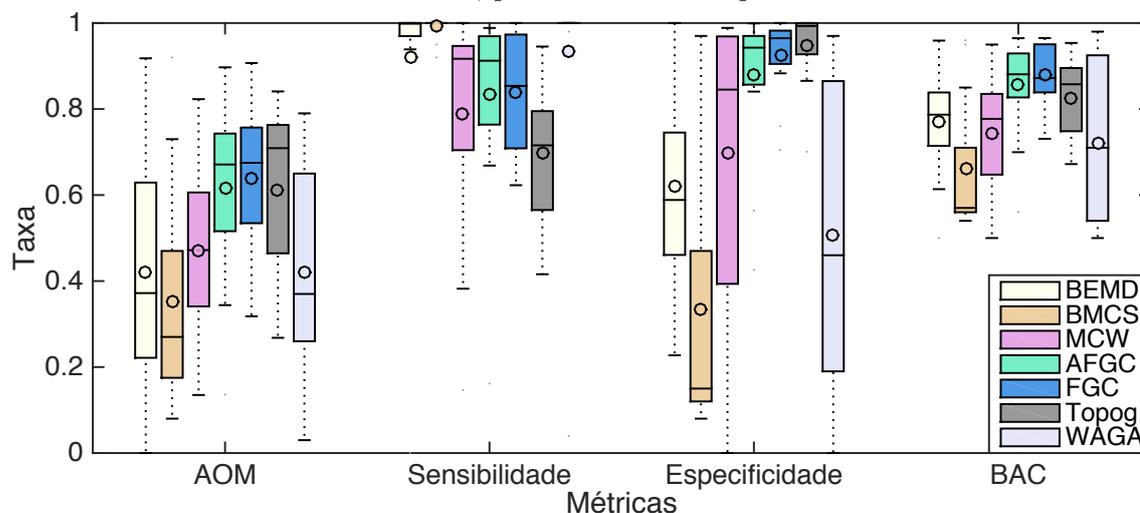
### 7.5 RESULTADOS PARA A BASE DA DADOS IRMA

Esta seção apresenta os resultados de segmentação das técnicas analisadas, para imagens da base de dados IRMA, onde foram utilizadas imagens de tecidos do tipo adiposo e fibroglandular, classificados pelos Tipo I e Tipo II, segundo o BIRADS. Nesta seção são feitas duas análises: análise de segmentação e análise de classificação, as quais são

**Figura 98** – Valores médios para as métricas AOM, Sensibilidade, Especificidade e BAC, comparando as técnicas propostas com o estado arte, para as lesões do tipo indefinido.



**Figura 99** – Valores médios para as métricas de Área, FF, Perímetro, FeretX, FeretY e Solidez, comparando as técnicas propostas com o estado arte, para as lesões do tipo indefinido.



Fonte: do autor.

descritas a seguir.

### 7.5.1 Análise de Segmentação

Nesta análise foram utilizadas 323 imagens da base, de tecido adiposo e fibroglandular, divididos quanto à forma em circunscrito e espiculado. Conforme descrito na seção 6.2.2, as imagens ouro foram marcadas por um especialista e utilizadas para comparação quanto à qualidade de segmentação.

Para esta análise, os parâmetros dos algoritmos do estado arte foram ajustados para

a base IRMA, considerando-se as métricas descritas na seção 6.5. Os melhores parâmetros encontrados para as técnicas FGC, BEMD, MCW e Abordagem Topográfica são descritos na Tabela 29. Os resultados para os diferentes parâmetros para os algoritmos Topográfico, BEMD, MCW e FGC são mostrados no Anexo A, na Tabela 45, Tabela 46, Tabela 47 e Tabela 48, respectivamente. Os algoritmos BMCS e WAGA não possuem parâmetros.

**Tabela 29** – Melhores parâmetros para os algoritmos BEMD, MCW, Abordagem Topográfica e *Fuzzy GrowCut*, para a base IRMA, utilizando as métricas relacionadas a forma da lesão.

Técnica	Parâmetros
BEMD	$r_i = 0, 4$
MCW	$size_{se} = 5, type_{se} = disk$
Topográfica	$n_{levels} = 60, depth = 8$
<i>Fuzzy GrowCut</i>	$n_{pontos} = 40, \alpha = 2$

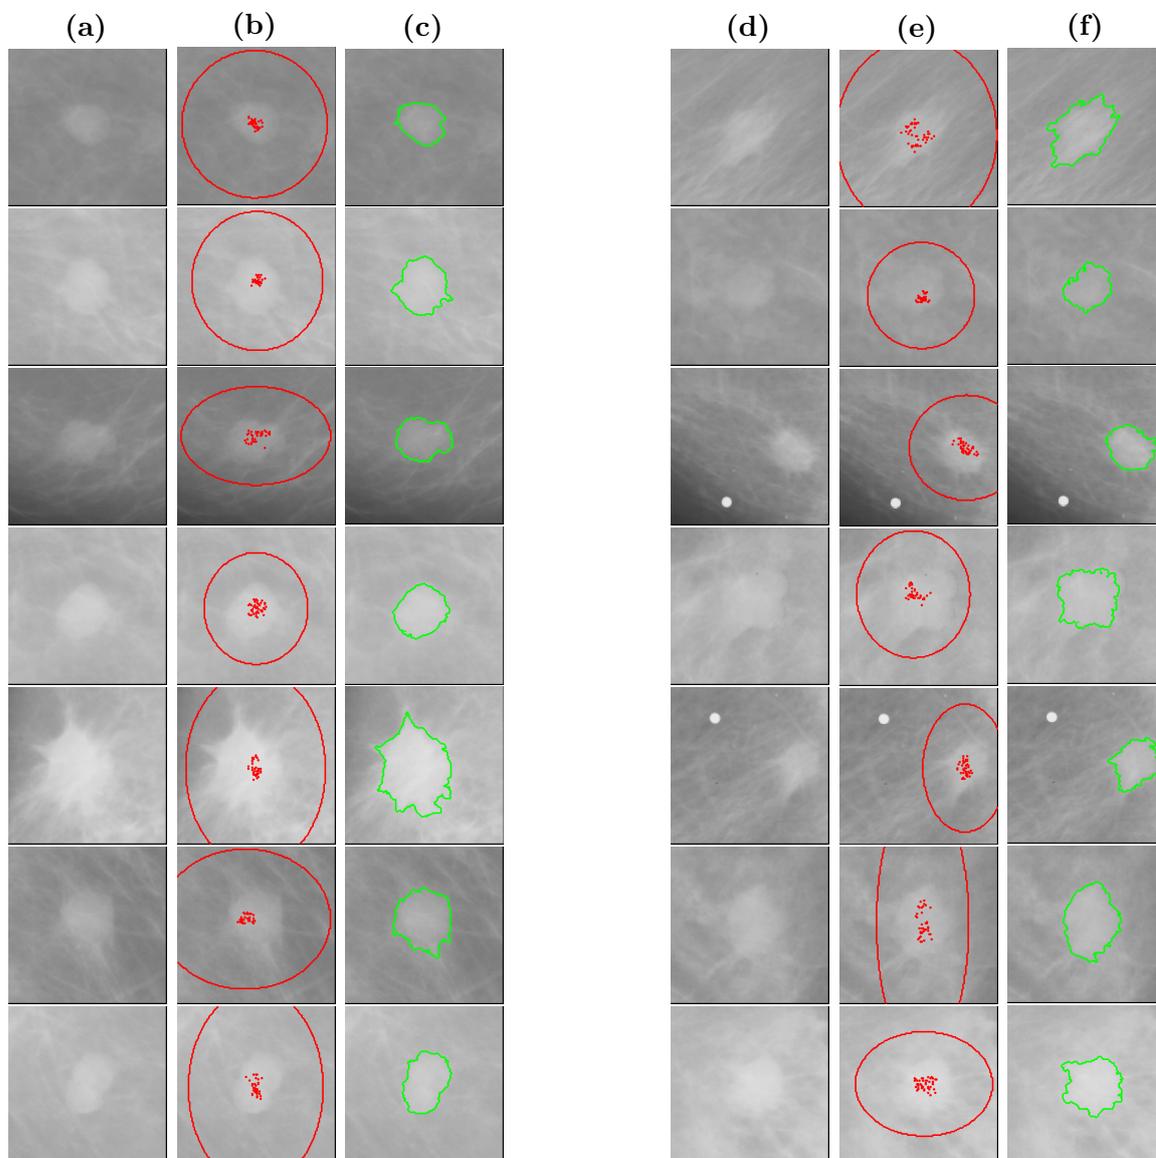
Inicialmente foi realizada uma análise qualitativa para a base IRMA. A Figura 100 mostra resultados das etapas de segmentação do método proposto, para imagens da base de dados IRMA. As colunas *a* e *d* da Figura 100 representa a região de interesse inicial fornecida pela base IRMA. As colunas *b* e *e* mostram as sementes obtidas a pelo processo de seleção automática, representadas pelos pontos vermelhos, e a região *fuzzy*-gaussiana, que é a região representada pela elipse vermelha. Por fim, as colunas *c* e *f* mostram a segmentação final do *Fuzzy GrowCut* representada pelo contorno verde.

Nos casos mostrados na Figura 100, observa-se que as sementes geradas automaticamente localizam-se dentro da região de lesão, que é a área mais clara da imagem. Baseado na distribuição das sementes, a região gaussiana possui um formato mais alongado ou arredondado. Para as imagens apresentadas na Figura 100, o método proposto consegue obter um contorno próximo à borda da lesão.

Foi realizada uma análise qualitativa da segmentação da lesão, mostrando o resultado de segmentação obtido pelas técnicas do estado da arte. A Figura 102 mostra os resultados obtidos para imagens da base IRMA. A primeira coluna mostra a região de interesse, que corresponde a imagem da base, enquanto as colunas *b*, *c*, *d*, *e*, *f* e *g* mostras os resultados de segmentação do método proposto, abordagem Topográfica, WAGA, BEMD, BMCS e MCW, respectivamente.

A técnica proposta, na coluna *b*, obteve um contorno próximo às bordas da lesão, para as imagens apresentadas. A abordagem Topográfica, na coluna *c*, também obteve uma boa segmentação para a maioria dos casos, mas ela não obteve segmentação tão bem definida em alguns casos, como na primeira, segunda e última imagens, onde a segmentação não foi bem sucedida. A abordagem baseada em WAGA, na coluna *d*, não obteve uma boa segmentação para alguns casos onde o contorno estava mal definido. As outras técnicas, nas

**Figura 100** – Segmentação do método proposto para as imagens da base de dados IRMA. (a) e (d) Região de Interesse; (b) e (e) Sementes geradas automaticamente e região *fuzzy* Gaussiana; (c) e (f) Segmentação Final.



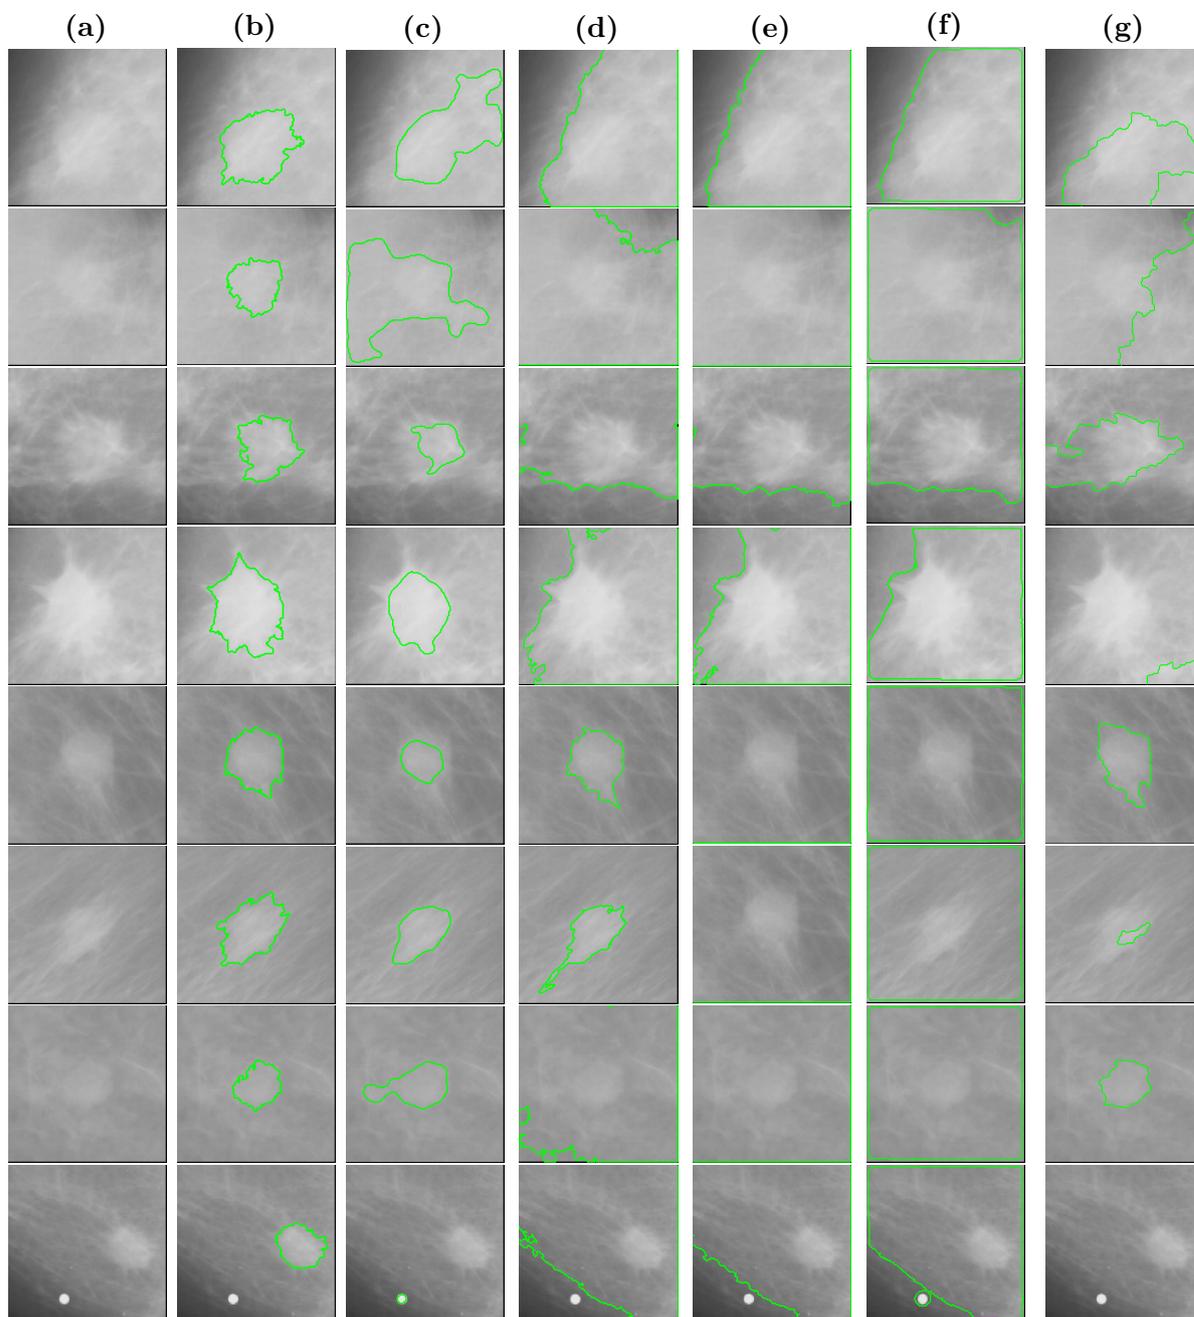
Fonte: do autor.

colunas *e*, *f* e *g*, não apresentaram boa segmentação para a maioria dos casos, segmentando a região de interesse inteira.

A análise quantitativa do resultado das segmentações para a base IRMA é mostrado na Tabela 30, onde a primeira coluna mostra as métricas utilizadas e as colunas seguintes mostram os valores obtidos por técnica. Os melhores valores para cada métrica estão representados em negrito.

A Tabela 30 mostra que, em média, o método proposto FGC obteve melhores resultado para a maioria das métricas analisadas. Em geral, todas as técnicas apresentam

**Figura 102** – Comparação da segmentação das técnicas analisadas. (a) Região de Interesse; (b) *Fuzzy GrowCut*; (c) Abordagem Topográfica; (d) WAGA; (e) BEMD; (f) BMCS; (g) MCW.



Fonte: do autor.

erros maiores quando comparados com os resultados obtidos utilizando a base Mini-MIAS. Isso acontece porque a marcação realizada pelo especialista é uma marcação aproximada da região, e não um contorno preciso. A marcação da imagem ouro da base Mini-MIAS, por outro lado foi realizada de forma mais precisa, pois a própria base fornecia indicação da localidade da lesão e do raio aproximado. A Figura 105 e Figura 105 mostram o *boxplot* para os resultados obtidos, para as métricas utilizadas.

**Tabela 30** – Valor médio das métricas para as técnicas analisadas, para lesões do tipo circunscrito e espiculado, para a base IRMA.

Métricas	BEMD	BMCS	MCW	FGC	AFGC	Topográfico	WAGA
$E_{\text{Área}}$	0,74±0,34	0,76±0,32	0,57±0,34	<b>0,43±0,29</b>	0,60±0,36	0,54±0,35	0,56±0,36
$E_{\text{FF}}$	0,38±0,23	<b>0,31±0,28</b>	0,43±0,33	0,34±0,20	0,37±0,27	0,37±0,26	0,35±0,24
$E_{\text{Per}}$	0,67±0,34	0,56±0,34	0,45±0,35	<b>0,40±0,29</b>	0,47±0,34	0,50±0,34	0,51±0,36
$E_{\text{FX}}$	0,51±0,38	0,48±0,37	0,41±0,37	<b>0,33±0,26</b>	0,39±0,35	0,42±0,34	0,40±0,36
$E_{\text{FY}}$	0,53±0,37	0,49±0,36	0,40±0,36	<b>0,30±0,25</b>	0,39±0,34	0,42±0,34	0,42±0,36
$E_{\text{Solidez}}$	0,16±0,22	<b>0,13±0,13</b>	0,27±0,34	0,13±0,16	0,17±0,22	0,17±0,23	0,16±0,23
AOM	0,32±0,27	0,32±0,26	0,33±0,28	<b>0,47±0,23</b>	0,39±0,27	0,39±0,27	0,41±0,29
Sensibilidade	0,91±0,22	<b>0,97±0,06</b>	0,52±0,38	0,65±0,26	0,79±0,29	0,68±0,31	0,77±0,29
Especificidade	0,37±0,32	0,28±0,25	0,66±0,40	<b>0,92±0,11</b>	0,53±0,40	0,79±0,25	0,64±0,35
BAC	0,64±0,13	0,63±0,11	0,59±0,17	<b>0,78±0,14</b>	0,66±0,16	0,74±0,14	0,71±0,15

Conforme pode ser visto na Figura 105, o método FGC, para a maioria dos casos, possui menor variação entre os erros obtidos, sendo mais constante na qualidade de segmentação quando comparado com as técnicas do estado da arte. O método adaptativo, AFGC apresentou uma alta variabilidade, com desempenho inferior ao obtido na base MiniMIAS, pois a base IRMA também possui tecidos do tipo fibroglandular, os quais apresentam maior dificuldade na segmentação. Porém, o método AFGC apresentou desempenho equivalente ao das técnicas do estado da arte. A Figura 105 mostra os resultados obtidos para as métricas AOM, Sensibilidade e Especificidade. As técnicas BEMD e BMCS apresentaram altos valores de Sensibilidade e baixa Especificidade. Isso se deve ao fato de na maioria das imagens o método não conseguiu encontrar a região correta, segmentando a imagem toda como lesão. O método FGC, por outro lado, conseguiu bom equilíbrio entre Sensibilidade e Especificidade, obtendo maior valor para a métrica BAC.

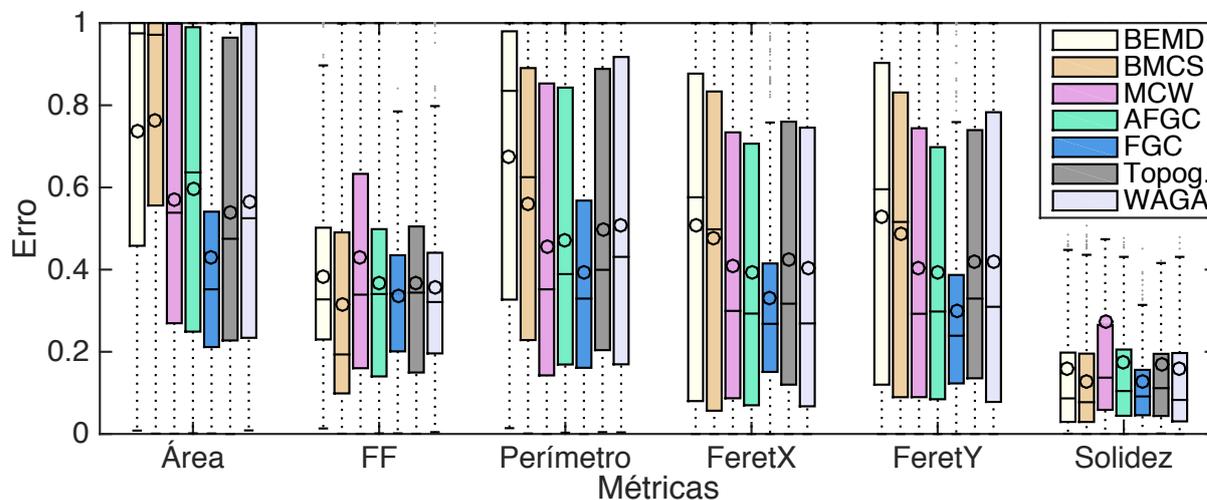
A Tabela 31 mostra os resultados do Teste de Wilcoxon aplicado para os resultados obtidos. Cada valor da tabela mostra o resultado do *p-value*, quando comparada técnica FGC com cada técnica do estado da arte. As células em negrito indicam que houve uma rejeição da hipótese nula, ou seja, o resultado da média da métrica é considerado estatisticamente diferente entre as técnicas.

**Tabela 31** – Valor do P-value do teste de sinal ranqueado de Wilcoxon, quando comparado os resultados do método *Fuzzy GrowCut* proposto com as técnicas analisadas, para a base IRMA, considerando lesões do tipo circunscrito e espiculado.

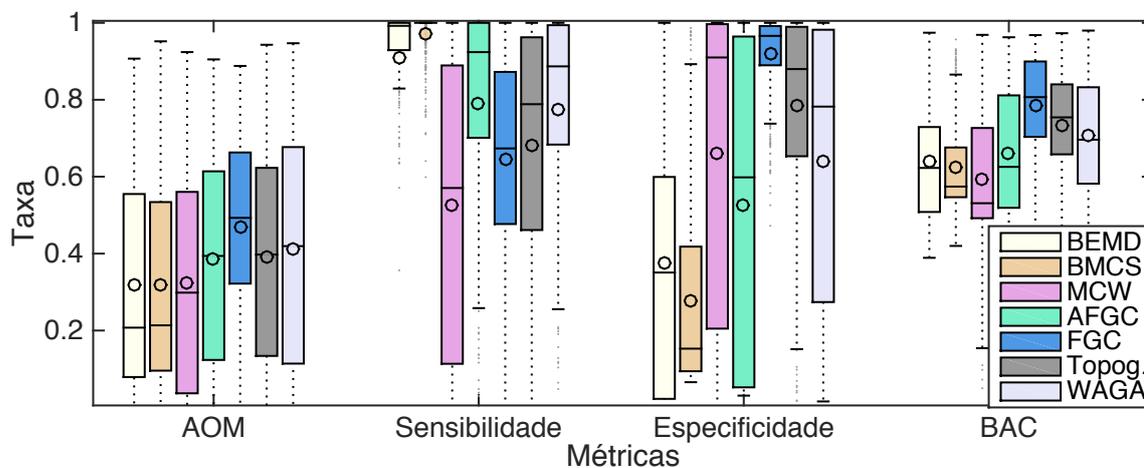
Comparação	$E_{\text{Área}}$	$E_{\text{FF}}$	$E_{\text{Per}}$	$E_{\text{FX}}$	$E_{\text{FY}}$	$E_{\text{Solidez}}$	AOM	BAC
Topográfico	<b>8,29e-07</b>	2,71e-01	<b>1,53e-12</b>	<b>7,97e-08</b>	<b>2,25e-10</b>	<b>5,24e-03</b>	<b>2,29e-08</b>	<b>3,06e-07</b>
WAGA	<b>1,37e-08</b>	2,03e-01	<b>1,68e-09</b>	<b>1,40e-03</b>	<b>1,68e-08</b>	1,34e-01	<b>1,05e-03</b>	<b>1,03e-10</b>
BEMD	<b>9,86e-27</b>	1,06e-02	<b>5,41e-30</b>	<b>1,62e-14</b>	<b>5,57e-20</b>	1,76e-01	<b>1,45e-12</b>	<b>1,21e-23</b>
BMCS	<b>3,00e-31</b>	1,31e-01	<b>1,13e-16</b>	<b>3,14e-12</b>	<b>4,06e-16</b>	<b>1,90e-02</b>	<b>1,76e-13</b>	<b>1,54e-29</b>
MCW	<b>3,26e-13</b>	<b>1,01e-04</b>	<b>4,81e-04</b>	<b>8,03e-04</b>	<b>3,82e-06</b>	<b>2,53e-13</b>	<b>1,01e-18</b>	<b>1,04e-42</b>

A partir da Tabela 31 observa-se que os resultados obtidos pelo algoritmo proposto são estatisticamente diferentes para a maioria das métricas.

**Figura 104** – Valores médios para as métricas AOM, Sensibilidade, Especificidade e BAC, comparando as técnicas propostas com o estado arte, para as lesões do tipo circunscrito e espiculado, para a base IRMA.



**Figura 105** – Valores médios para as métricas de Área, FF, Perímetro, FeretX, FeretY e Solidez, comparando as técnicas propostas com o estado arte, para as lesões do tipo circunscrito e espiculado, para a base IRMA.



Fonte: do autor.

Uma segunda análise foi realizada comparando apenas os resultados de segmentação obtidos para lesões do tipo circunscrito. A Tabela 32 mostra os resultados obtidos.

A Tabela 32 mostra que o método FGC obteve melhores resultados para a maioria das métricas. A técnica BMCS obteve menores valores para as métricas de fator de forma, solidez e sensibilidade. No entanto, ela apresenta uma baixa taxa de especificidade, que indica a taxa de verdadeiro negativo. Como descrito anteriormente, os resultados das métricas devem ser analisados em conjunto, pois podem haver casos isolados em que o algoritmo não obtém uma segmentação com área próxima da imagem ouro, mas pode apresentar um fator de forma próximo do esperado. Analisando o conjunto das

**Tabela 32** – Valor médio das métricas para as técnicas analisadas, para lesões do tipo circunscrito, para a base IRMA.

Métricas	BEMD	BMCS	MCW	FGC	AFGC	Topográfico	WAGA
$E_{\text{Área}}$	0,87±0,26	0,88±0,26	0,61±0,36	<b>0,48±0,35</b>	0,67±0,37	0,64±0,37	0,66±0,38
$E_{\text{FF}}$	0,37±0,21	<b>0,16±0,14</b>	0,42±0,36	0,36±0,18	0,32±0,25	0,34±0,26	0,36±0,22
$E_{\text{Per}}$	0,85±0,22	0,74±0,26	0,54±0,39	<b>0,48±0,33</b>	0,61±0,33	0,60±0,36	0,65±0,35
$E_{\text{FX}}$	0,70±0,30	0,66±0,30	0,49±0,40	<b>0,39±0,31</b>	0,52±0,35	0,53±0,35	0,53±0,37
$E_{\text{FY}}$	0,71±0,29	0,66±0,30	0,49±0,40	<b>0,34±0,30</b>	0,52±0,34	0,53±0,35	0,53±0,36
$E_{\text{Solidez}}$	0,13±0,22	<b>0,06±0,07</b>	0,32±0,40	0,13±0,20	0,15±0,26	0,19±0,26	0,15±0,25
AOM	0,21±0,23	0,21±0,22	0,31±0,30	<b>0,46±0,28</b>	0,33±0,29	0,32±0,26	0,34±0,29
Sensibilidade	0,92±0,23	<b>0,97±0,06</b>	0,48±0,39	0,72±0,27	0,77±0,32	0,72±0,32	0,81±0,28
Especificidade	0,33±0,30	0,26±0,23	0,74±0,37	<b>0,88±0,12</b>	0,57±0,38	0,74±0,26	0,58±0,36
BAC	0,62±0,12	0,61±0,10	0,61±0,20	<b>0,80±0,17</b>	0,67±0,18	0,73±0,15	0,69±0,15

métricas, a técnica proposta obteve melhores resultados considerando apenas lesões do tipo circunscrito. A versão adaptativa, AFGC, obteve desempenho próximo da abordagem topográfica, que obteve melhores resultados, depois do FGC. A Figura 107 e Figura 107 mostram o *boxplot* para das métricas para os resultados obtidos para segmentação de lesões do tipo circunscrito.

Resultados da Figura 107 mostram que o método FGC obteve menor variabilidade, conseguindo melhores valores em média e com menor valor mínimo e erro máximo quando comparado com as técnicas do estado da arte. A Figura 107 melhores resultados para o algoritmo proposto, para as métricas AOM, Especificidade e BAC. A abordagem Topográfica também obteve bons resultados quando comparado com as demais técnicas.

Foi realizado o teste de Wilcoxon a partir desses resultados, comparando o algoritmo FGC com os trabalhos do estado da arte. A análise é apresentada na Tabela 33.

**Tabela 33** – Valor do P-value do teste de sinal ranqueado de Wilcoxon, quando comparado os resultados do método *Fuzzy* GrowCut proposto com as técnicas analisadas, para a base IRMA, considerando lesões do tipo circunscrito.

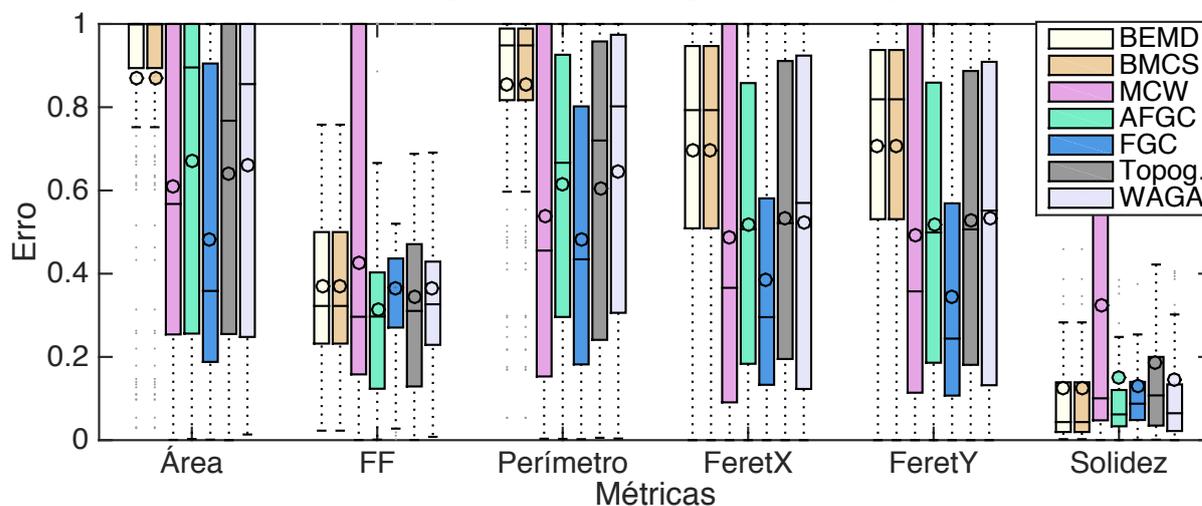
Comparação	$E_{\text{Área}}$	$E_{\text{FF}}$	$E_{\text{Per}}$	$E_{\text{FX}}$	$E_{\text{FY}}$	$E_{\text{Solidez}}$	AOM	BAC
Topográfico	<b>8,22e-08</b>	<b>7,48e-03</b>	<b>8,57e-10</b>	<b>3,78e-12</b>	<b>1,07e-13</b>	<b>3,79e-03</b>	<b>1,86e-12</b>	<b>1,73e-10</b>
WAGA	<b>8,39e-10</b>	7,98e-01	<b>3,31e-12</b>	<b>8,75e-10</b>	<b>2,03e-14</b>	4,35e-01	<b>5,18e-09</b>	<b>8,22e-11</b>
BEMD	<b>3,84e-23</b>	8,27e-01	<b>8,95e-29</b>	<b>1,04e-23</b>	<b>1,23e-25</b>	7,24e-02	<b>1,20e-18</b>	<b>3,09e-17</b>
BMCS	<b>3,84e-23</b>	8,27e-01	<b>8,95e-29</b>	<b>1,04e-23</b>	<b>1,23e-25</b>	7,24e-02	<b>1,20e-18</b>	<b>3,09e-17</b>
MCW	<b>2,88e-07</b>	4,40e-01	<b>8,76e-03</b>	<b>1,08e-04</b>	<b>1,69e-07</b>	<b>4,79e-06</b>	<b>5,97e-11</b>	<b>3,85e-21</b>

Resultados da Tabela 33 confirmam que o FGC apresenta resultados estatisticamente diferentes, para a maioria das métricas, com exceção das métricas de fator de forma e solidez.

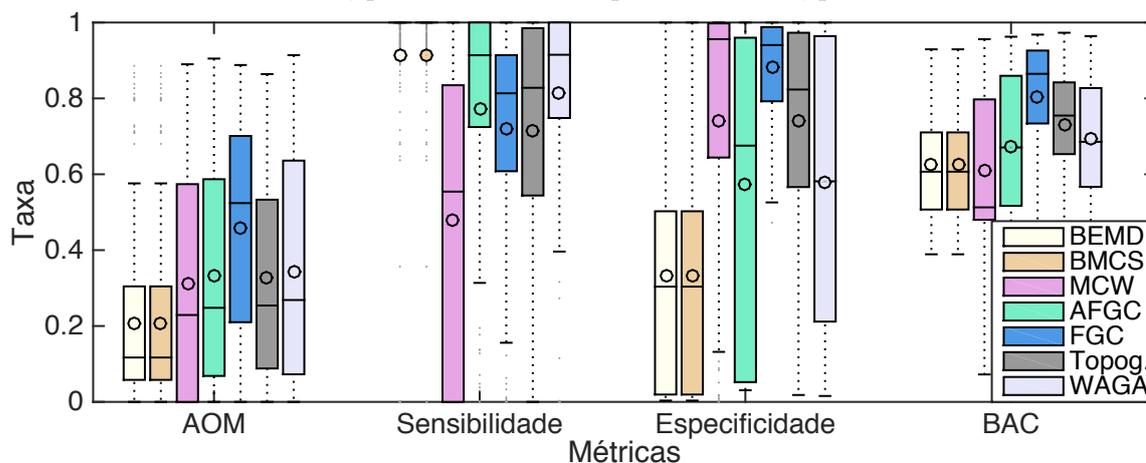
A análise também foi realizada considerando apenas lesões do tipo espiculado, para a base IRMA. Resultados obtidos para as métricas analisadas são mostrados na Tabela 34.

De acordo com a Tabela 34, as técnicas com melhores resultados foram o FGC e

**Figura 106** – Valores médios para as métricas AOM, Sensibilidade, Especificidade e BAC, comparando as técnicas propostas com o estado arte, para as lesões do tipo circunscrito, para a base IRMA.



**Figura 107** – Valores médios para as métricas de Área, FF, Perímetro, FeretX, FeretY e Solidez, comparando as técnicas propostas com o estado arte, para as lesões do tipo circunscrito, para a base IRMA.



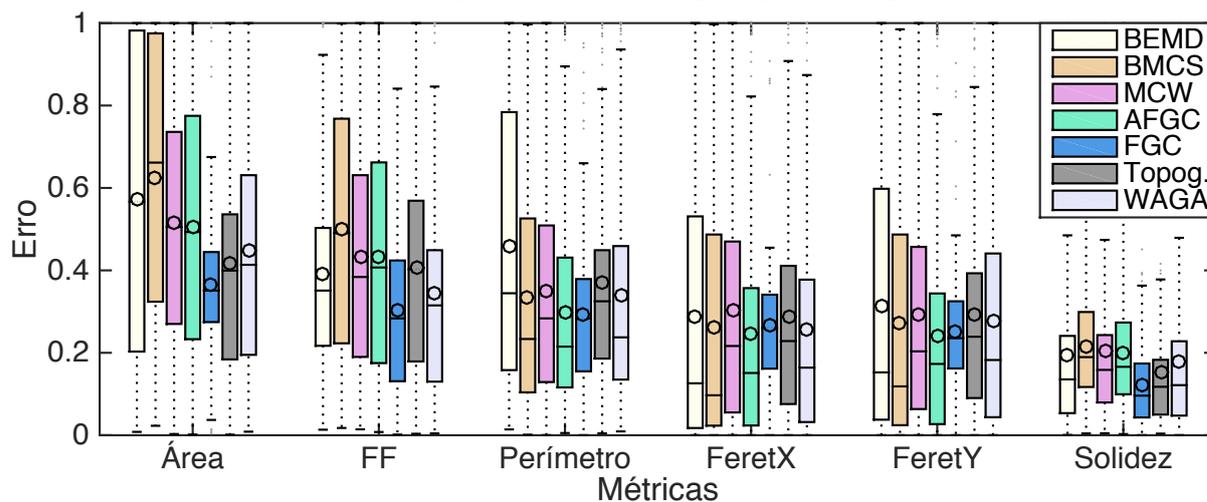
Fonte: do autor.

**Tabela 34** – Valor médio das métricas para as técnicas analisadas, para lesões do tipo espiculado, para a base IRMA.

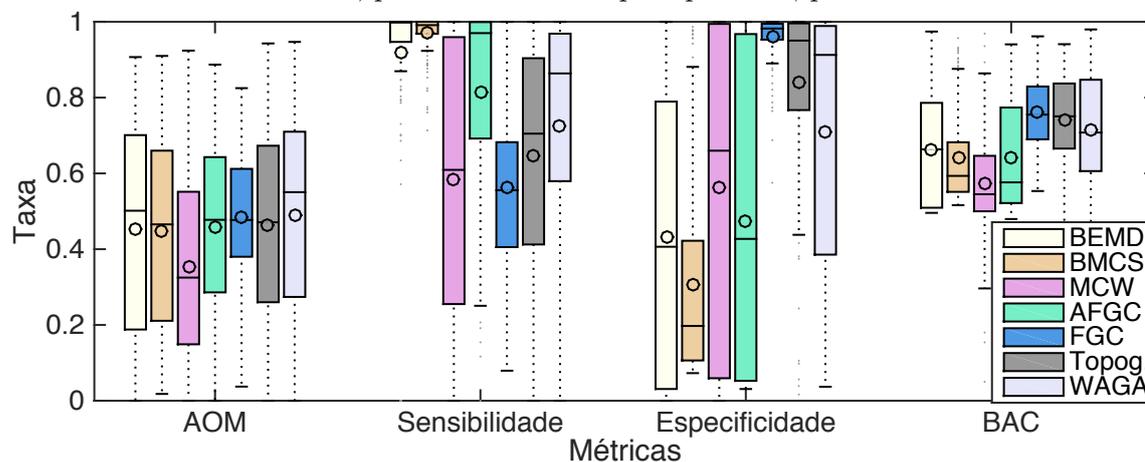
Métricas	BEMD	BMCS	MCW	FGC	AFGC	Topográfico	WAGA
$E_{Área}$	0,57±0,37	0,62±0,33	0,52±0,30	<b>0,36±0,18</b>	0,51±0,32	0,42±0,30	0,45±0,31
$E_{FF}$	0,39±0,25	0,50±0,29	0,43±0,28	<b>0,31±0,21</b>	0,43±0,28	0,40±0,26	0,35±0,26
$E_{Per}$	0,46±0,34	0,34±0,30	0,35±0,27	<b>0,29±0,19</b>	0,30±0,26	0,37±0,26	0,34±0,29
$E_{FX}$	0,29±0,34	0,26±0,32	0,30±0,29	0,27±0,16	0,24±0,27	0,29±0,27	<b>0,26±0,29</b>
$E_{FY}$	0,31±0,34	0,27±0,31	0,29±0,28	<b>0,25±0,16</b>	0,24±0,26	0,29±0,26	0,28±0,30
$E_{Solidez}$	0,19±0,21	0,22±0,14	0,21±0,21	<b>0,12±0,10</b>	0,20±0,15	0,15±0,17	0,18±0,20
AOM	0,45±0,27	0,45±0,26	0,35±0,24	0,48±0,17	0,46±0,22	0,47±0,25	<b>0,49±0,26</b>
Sensibilidade	0,90±0,21	<b>0,97±0,05</b>	0,58±0,35	0,56±0,21	0,81±0,25	0,64±0,30	0,73±0,31
Especificidade	0,42±0,35	0,31±0,27	0,56±0,42	<b>0,96±0,06</b>	0,47±0,42	0,84±0,23	0,71±0,33
BAC	0,66±0,14	0,64±0,12	0,57±0,14	<b>0,76±0,11</b>	0,64±0,14	0,74±0,12	0,72±0,14

WAGA. Para a maioria das métricas o FGC obteve melhores resultados. Para as métricas *FeretX* e AOM, ambas obtiveram valores próximos. Apesar de o BMCS obter maior valor de sensibilidade, o FGC obteve melhor valor de Acurácia Balanceada. O *boxplot* dos resultados obtidos para imagens espiculadas é mostrado na Figura 109 e Figura 109.

**Figura 108** – Valores médios para as métricas AOM, Sensibilidade, Especificidade e BAC, comparando as técnicas propostas com o estado arte, para as lesões do tipo espiculado, para a base IRMA.



**Figura 109** – Valores médios para as métricas de Área, FF, Perímetro, FeretX, FeretY e Solidez, comparando as técnicas propostas com o estado arte, para as lesões do tipo espiculado, para a base IRMA.



Fonte: do autor.

A Figura 109 mostra que a técnica FGC obteve menor intervalo entre valores máximo e mínimos de erro. A técnica com abordagem Topográfica também obteve bons resultados comparado com o estado da arte, porém com maior variância. A abordagem adaptativa, AFGC, mostrou-se com resultados equivalente à técnica MCW, porém com resultados melhores do que o BEMD e BMCS. A Figura 109 também mostra melhores resultados do FGC para as métricas AOM, Especificidade e BAC.

O teste de Wilcoxon foi aplicado para os resultados obtidos para imagens do tipo

espiculado, comparando a técnica FGC com BEMD, BMCS, MCW, Topográfico e WAGA. Os resultados são apresentados na Tabela 35.

**Tabela 35** – Valor do P-value do teste de sinal ranqueado de Wilcoxon, quando comparado os resultados do método *Fuzzy* GrowCut proposto com as técnicas analisadas, para a base IRMA, considerando lesões do tipo espiculado.

Comparação	$E_{\text{Área}}$	$E_{\text{FF}}$	$E_{\text{Per}}$	$E_{\text{FX}}$	$E_{\text{FY}}$	$E_{\text{Solidez}}$	AOM	BAC
Topográfico	2.47e-01	<b>1.38e-04</b>	<b>5.81e-04</b>	8.47e-01	3.57e-01	2.89e-01	6.61e-01	6.84e-01
WAGA	8,02e-02	7,00e-02	3,13e-01	<b>3,35e-02</b>	6,95e-01	<b>4,64e-03</b>	1,82e-01	<b>2,50e-02</b>
BEMD	<b>1,84e-06</b>	<b>3,50e-04</b>	<b>2,00e-05</b>	<b>5,80e-01</b>	5,20e-01	<b>3,00e-04</b>	4,55e-01	<b>4,38e-08</b>
BMCS	<b>1,51e-10</b>	<b>8,16e-11</b>	6,55e-01	3,32e-01	8,99e-01	<b>3,74e-15</b>	3,31e-01	<b>6,75e-13</b>
MCW	9,59e-07	1,84e-06	8,63e-02	7,21e-01	6,36e-01	<b>8,19e-09</b>	<b>1,05e-08</b>	<b>1,69e-23</b>

Resultados do teste de hipótese apresentado na Tabela 35 mostram similaridade estatística entre o FGC e a abordagem Topográfica, para a maioria das métricas, assim como quando comparado com as técnicas MCW e WAGA.

### 7.5.2 Análise de Classificação

Esta seção apresenta os resultados de classificação da segmentação das técnicas analisadas, para imagens da base de dados IRMA, onde foram utilizados tecidos do tipo adiposo e fibroglandular, classificados pelos Tipo I e Tipo II, segundo o BIRADS. As lesões desses tipos de tecido, para a base imagens IRMA, contém 685 imagens classificadas como circunscrito, espiculado e indefinido.

Para esta análise, foi realizada a otimização dos parâmetros para cada técnica comparada do estado da arte para a base IRMA através de uma busca exaustiva, considerando a métrica de precisão obtida pelo classificador. Desta forma, os resultados apresentados utilizam as configurações de parâmetros que apresentam maior taxa de classificação. Os melhores parâmetros encontrados para as técnicas FGC, BEMD, MCW e Abordagem Topográfica são descritos na Tabela 36. Os resultados para os diferentes parâmetros também são mostrados no Anexo A. Os algoritmos BMCS e WAGA não possuem parâmetros.

Conforme descrito nos métodos de avaliação do capítulo 6, as imagens segmentadas de cada técnica foram submetidas para um classificador para identificar o tipo da lesão de acordo com suas características de forma e de margem. O classificador utilizado foi uma MLP, o qual é utilizado para classificar a imagem em benigno ou maligno. A análise foi separada de acordo com o tipo de tecido, e para cada tecido ela foi subdividida analisando dois cenários: a) lesão circunscrita e espiculada e b) circunscrita, espiculada e indistinta. Os resultados de classificação para os cenários descritos são apresentados na Tabela 37.

A Tabela 37 mostra que o FGC obteve maior precisão quando usado o classificador para identificar imagens segmentadas em benigno e maligno, aplicada para tecido adiposo e usando massas circunscrita e espiculada. Quando incluso também lesão indefinida,

**Tabela 36** – Melhores parâmetros para os algoritmos BEMD, MCW, Abordagem Topográfica e *Fuzzy GrowCut*, para a base IRMA, utilizando a métrica de precisão.

Técnica	Tipo 1		Tipo 2	
	circ+spic	circ+spic+indef.	circ+spic	circ+spic+indef.
BEMD	$r_i = 2$	$r_i = 2$	$r_i = 2$	$r_i = 2$
MCW	$size_{se} = 7,$ $type_{se} = square$	$size_{se} = 3,$ $type_{se} = diamond$	$size_{se} = 3,$ $type_{se} = diamond$	$size_{se} = 3,$ $type_{se} = diamond$
Topográfica	$n_{levels} = 20,$ $depth = 3$	$n_{levels} = 50,$ $depth = 7$	$n_{levels} = 60,$ $depth = 5$	$n_{levels} = 10,$ $depth = 2$
Fuzzy GrowCut	$n_{pontos} = 40,$ $\alpha = 4$	$n_{pontos} = 25,$ $\alpha = 6$	$n_{pontos} = 40,$ $\alpha = 4$	$n_{pontos} = 25,$ $\alpha = 6$

**Tabela 37** – Taxa de Classificação usando imagens segmentadas das técnicas analisadas, para tecidos adiposo e fibroglandular.

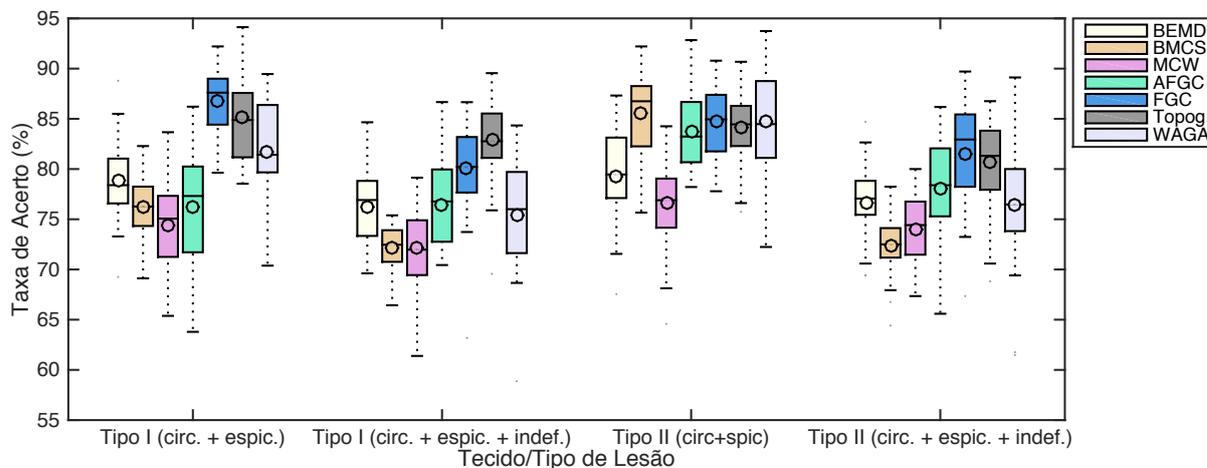
Técnicas	Tecido Adiposo		Tecido Fibroglandular	
	circ + spic	circ.+spic+indef	circ+spic	circ+spic+indef
BEMD	78,95±4,04%	76,25±3,67%	79,28±4,74%	76,63±3,79%
BMCS	76,15±3,22%	72,07±2,41%	74,48±3,67%	72,37±2,96%
MCW	74,41±4,49%	72,18±3,93%	76,61±4,47%	73,89±3,61%
AFGC	76,21±5,51%	75,67±4,60%	82,48±4,80%	78,60±5,33%
FGC	<b>86,75±3,38%</b>	80,00±4,92%	<b>84,84±3,66%</b>	<b>81,52±5,47%</b>
Topográfico	85,17±4,16%	<b>82,85±4,24%</b>	84,05±3,78%	80,77±4,35%
WAGA	81,64±5,35%	75,48±5,51%	81,01±5,94%	76,32±5,97%

na terceira coluna, a média de classificação se aproxima das abordagens Topográfica e WAGA. Para tecido fibroglandular, todas as técnicas, com exceção do BEMD, obtiveram desempenho similar quando considerado apenas massas circunscritas e espiculadas. Quando adicionado lesão indistinta para tecido fibroglandular, a abordagem FGC obteve maiores resultados. A versão adaptativa AFGC não esteve entre os melhores resultados, mas ainda assim conseguiu alcançar resultados próximos das técnicas do estado da arte.

O *boxplot* dos resultados da Tabela 37 são apresentados na Figura 110.

Conforme pode ser observado na Figura 110, a maior diferença de resultados entre as técnicas foi no primeiro cenário, quando usado tecido adiposo (tipo I) e apenas lesões circunscritas e espiculadas. Para avaliar se os resultados foram estatisticamente diferentes, foi realizado o teste de hipótese. O teste de hipótese foi feito utilizando teste ranqueado de Wilcoxon, considerando a hipótese nula com médias iguais, usando índice de confiança de 95%. O teste de Wilcoxon foi feito comparando os resultados da técnica proposta contra as técnicas analisadas. Os resultados desse teste são mostrados na Tabela 38.

**Figura 110** – Boxplot dos resultados de taxa de classificação para as técnicas analisadas.



Fonte: do autor.

**Tabela 38** – P-value do teste ranqueado de Wilcoxon comparando o método proposto *Fuzzy GrowCut* com as outras técnicas analisadas.

Comparação	Tecido Adiposo		Tecido Fibrograndular	
	circ. + espic.	circ.+espic.+indist.	circ. + espic.	circ.+espic.+indist.
Topográfico	0,2249	<b>0,0062</b>	0,4165	0,6658
AFGC	<b>1,7333E-08</b>	<b>0,0104</b>	0,1714	<b>0,0107</b>
WAGA	<b>6,6392E-04</b>	<b>6,1564E-04</b>	0,8290	<b>0,0070</b>
BEMD	<b>6,0351E-10</b>	<b>5,2872E-04</b>	<b>9,3028E-05</b>	<b>0,0023</b>
BMCS	<b>1,7322E-06</b>	<b>7,6866e-06</b>	0,3524	<b>1,0224E-05</b>
MCW	<b>1,7333E-06</b>	<b>1,1939E-05</b>	<b>9,3106E-06</b>	<b>1,9485E-05</b>

O valor em negrito, na Tabela 38, representa as situações nas quais a hipótese nula foi rejeitada. Isso significa que a abordagem proposta e a técnica comparada são estatisticamente diferentes. Para os outros casos significa que elas são estatisticamente similares. Os resultados da segunda coluna da Tabela 38 significam que para tecido adiposo, usando apenas massas circunscritas e espiculadas, a abordagem proposta obteve resultados estatisticamente diferentes quando comparado com as outras técnicas, com exceção da abordagem Topográfica, onde os resultados se mostraram equivalentes. Apenas para o cenário utilizando tecido adiposo, com lesão do tipo circunscrito, espiculado e indistinto, a abordagem Topográfica apresentou diferença estatística. Portanto, pode-se dizer que a técnica proposta obteve maior precisão quando usado as suas imagens segmentadas junto ao classificador. Para tecido adiposo, incluindo lesões do tipo indistinto, a técnica proposta foi estatisticamente diferente quando comparada com todas as técnicas analisadas. No entanto a, a abordagem Topográfica obteve resultados melhores, indicando que estatisticamente o FGC obteve a segunda melhor taxa de classificação comparado com os métodos do estado a arte. Para tecido fibroso, não houve diferença estatística significativa entre o FGC e

a abordagem Topográfica, FGC, WAGA e BMCS quando usado lesões circunscritas e espiculadas. Ao adicionar lesões indistintas, o FGC mostrou-se equivalente à abordagem Topográfica, mas estatisticamente superior aos outros métodos analisados.

### 7.5.3 Análise com Imagens sem Lesão

Existem cenários na prática clínica em que o médico pode selecionar uma região de interesse sem lesão. A maioria das técnicas de segmentação de imagens de mamografia não realiza uma análise de seu comportamento em imagens sem lesão. Em teoria, ao ser fornecida uma imagem sem lesão, a técnica de segmentação não deveria retornar nenhum contorno na imagem resultante, ou fornecer algum padrão quando a imagem não houvesse lesão.

A análise a seguir visa observar o comportamento da técnica proposta com imagens sem lesão, chamadas nessa seção de imagens normais, diferentes das imagens com lesão. Ao aplicar o algoritmo proposto, foi observado a imagem resultante não é uma imagem sem segmentação, mas sim uma imagem com múltiplas ilhas de segmentação. Também foi observado que isso ocorre apenas em imagens sem lesão. A Figura 111 mostra alguns exemplos de segmentação.

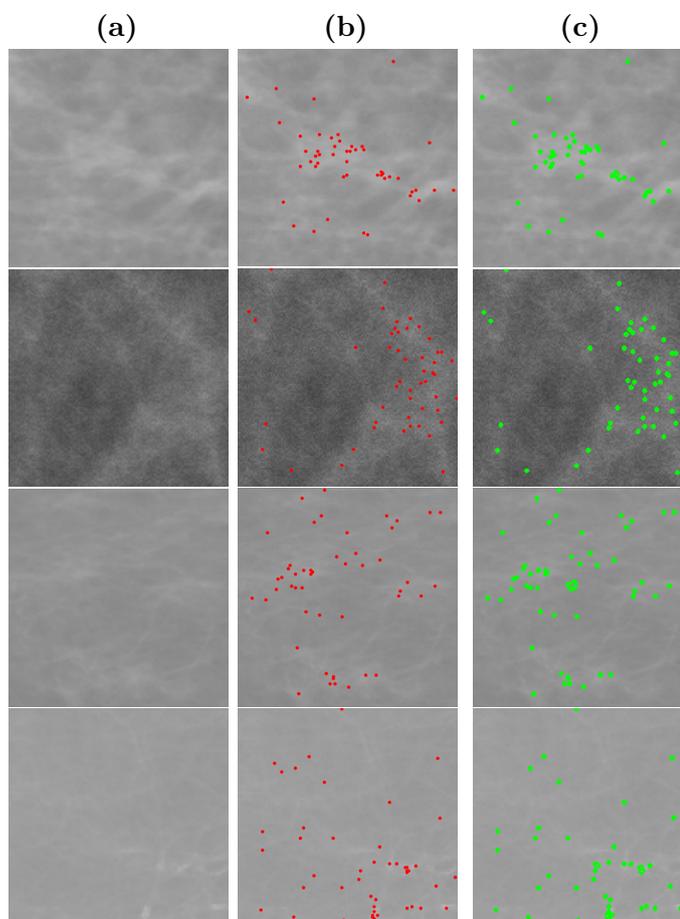
A coluna *a* da Figura 111 mostra a região de interesse inicial, a coluna *b* mostra as sementes geradas automaticamente e a coluna *c* mostra a imagem final segmentada, para quatro imagens da base de dados. Como as imagens sem lesão não possuem lesão a ser segmentada, o algoritmo não consegue evoluir a partir das sementes iniciais e formar uma única região de segmentação. Desta forma, as imagens segmentadas para imagens sem lesão formam um padrão, onde a segmentação é composta por múltiplas ilhas pequenas de segmentação. O mesmo padrão ocorre para as demais imagens sem lesão da base de dados. Sendo assim, esse padrão será utilizado na análise seguinte para identificar se uma imagem contém lesão ou não. As outras técnicas analisadas não contêm originalmente uma abordagem para averiguar a presença de lesão. Dessa forma, foi proposto um padrão de características de imagens sem lesão, conforme mostrado na Tabela 39.

**Tabela 39** – Características adotadas para identificar uma imagem sem lesão, para cada uma das técnicas analisadas.

Técnica	Característica
BEMD	Sem segmentação na imagem final
BMCS	Segmenta a imagem inteira
MCW	Segmenta a imagem toda
<i>Fuzzy Growcut</i>	Múltiplas ilhas de segmentação
Topográfico	Sem segmentação na imagem final
WAGA	Segmenta a imagem inteira

As características selecionadas para cada técnica analisada foram identificadas

**Figura 111** – Segmentação do algoritmo proposto, usando imagens sem lesão.  
(a) Região de Interesse; (b) Sementes geradas automaticamente;  
(c) Segmentação Final.

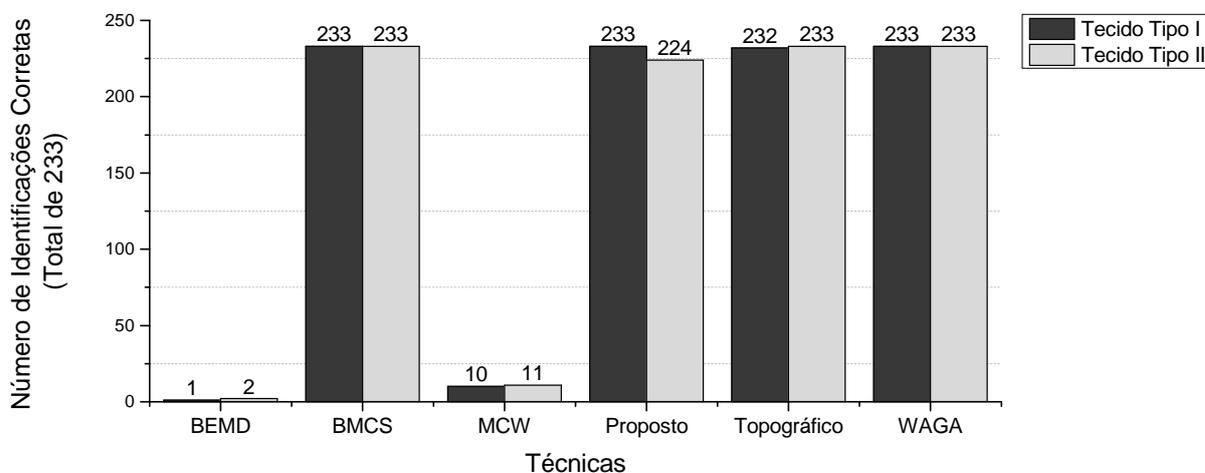


Fonte: do autor.

empiricamente, através da observação do padrão de segmentação de cada técnica para imagens sem lesão, pois esses padrões não são definidos no estado da arte. Por exemplo, para a técnica com abordagem Topográfica, foi observado que a segmentação das imagens sem lesão eram imagens sem segmentação, enquanto que para a técnica baseada em Wavelet ela segmentava a imagem inteira quando não havia lesão.

A análise do número de imagens selecionadas por esse critério, para cada técnica é mostrada na Figura 113. O número de imagens sem lesão, para cada tipo de tecido, é igual a 233. A Figura 113 mostra que as técnicas BMCS, o algoritmo proposto, a abordagem Topográfica e a baseada em Wavelets tiveram acerto próximo de 100% para os dois tipos de tecido, enquanto que para as técnicas BEMD e MCW não foi possível identificar corretamente utilizando as características selecionadas. Esse resultado indica que a técnica proposta também pode ser utilizada para identificar se a região de interesse possui lesão. Isso é importante pois caso o médico selecione incorretamente uma região de interesse, a técnica pode identificar a ausência de lesão com alta precisão.

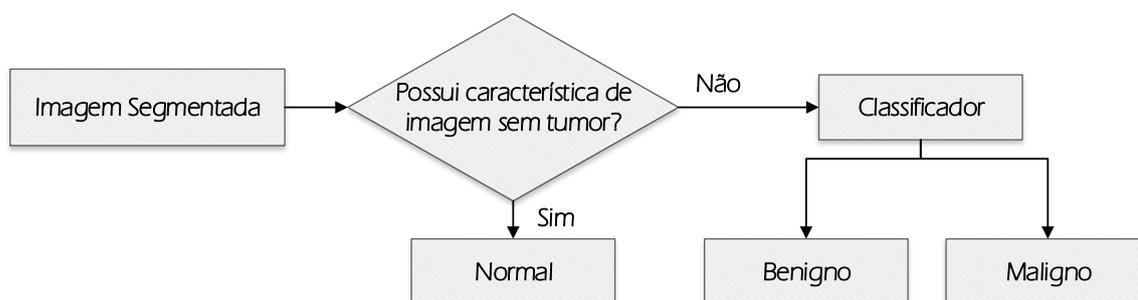
**Figura 113** – Número de imagens do tipo normal identificadas corretamente, para cada técnica analisada.



Fonte: do autor.

O método de identificação de imagens sem lesão foi adicionado à metodologia proposta, obtendo o fluxograma da Figura 114.

**Figura 114** – Etapa de Classificação da Imagem Segmentada.



Fonte: do autor.

A Figura 114 mostra que uma vez obtida a imagem segmentada pela técnica de segmentação analisada, é verificado se a imagem possui a característica definida na Tabela 39. Em caso positivo a imagem é classificada como normal, caso contrário, a imagem é submetida ao classificador, onde será classificada como benigno ou maligno.

Na Tabela 40 são mostrados os resultados de classificação adicionando-se as imagens do tipo normal.

Conforme apresentado na Tabela 40, a técnica proposta obteve alta taxa de acerto quando aplicado para o tecido adiposo, analisando imagens sem lesão e com lesão do tipo circunscrito e espiculado. Quando adicionado também lesão do tipo indefinido, os resultados mostram-se equivalentes com a Topográfica. Para o tecido fibroglandular, a abordagem

**Tabela 40** – Taxa de Classificação usando imagens segmentadas das técnicas analisadas, para tecidos adiposo e fibroglandular, incluindo imagens sem lesão.

Técnica	Tecido Adiposo		Tecido Fibroglandular	
	Normal + Circ. + Spic.	Normal + Circ. +Spic.+Indef.	Normal + Circ. + Spic	Normal + Circ. +Spic.+Indef.
BEMD	31,43%	45,69%	36,89%	45,82%
BMCS	90,58%	83,33%	88,28%	83,61%
MCW	31,97%	44,81%	37,75%	45,76%
AFGC	90,61%	85,48%	89,86%	85,73%
FGC	<b>94,77%</b>	88,06%	90,95%	87,46%
Topográfico	93,89%	<b>89,59%</b>	90,84%	<b>88,59%</b>
WAGA	92,75%	85,36%	<b>91,28%</b>	85,95%

também consegue obter bons resultados, sendo equivalente à abordagem Topográfica e WAGA.

## 7.6 ANÁLISE DO TEMPO DE SIMULAÇÃO

Foi feita a análise do tempo médio, em segundos, necessário para cada técnica realizar a segmentação de uma imagem da base IRMA. Para a análise do tempo médio foi considerada apenas a etapa de segmentação, sendo analisado tempo médio para todas as imagens com tecido tipo I e tipo II. A Tabela 41 mostra os resultados dos tempos de cada técnica.

**Tabela 41** – Tempo médio de simulação (em segundos) de cada técnica analisada.

Técnica	Tempo Médio (segundos)
BEMD	9,06
BMCS	298,92
MCW	0,11
FGC	158,14
Topográfico	0,14
WAGA	0,03

Conforme mostrado na Tabela 41, a técnica proposta possui tempo mais alto do que a maioria técnicas analisadas, com 158,14 segundos, mas ainda assim é um tempo viável para a análise de um grande número de imagens. Conforme mostrado nos resultados anteriores, o tempo elevado é compensado com a melhoria na qualidade de segmentação. Além disso, a técnica proposta pode ser paralelizada para otimizar seu tempo de simulação.

## 7.7 DISCUSSÃO

Os resultados apresentados compararam as abordagens propostas com técnicas do estado da arte através de uma análise qualitativa e quantitativa. A análise qualitativa indica que o *Fuzzy GrowCut* obtém melhor segmentação comparado com as técnicas do estado da arte, tendo a vantagem de apresentar flexibilidade quanto à etapa de inicialização. Além disso, a versão adaptativa AFGC não requer parâmetros. Apesar do avanço das técnicas de segmentação de lesões na literatura, pode-se observar que as técnicas de segmentação ainda tem dificuldade para alcançar uma segmentação de lesão precisa, especialmente para lesões do tipo espiculado e indefinido, por ser um problema complexo. Este trabalho contribui melhorando a qualidade da segmentação semi-supervisionada para esses cenários. No entanto, melhorarias ainda são necessárias para a segmentação se aproximar da imagem ouro.

A maioria das técnicas de segmentação de lesão semi-supervisionadas do estado da arte usam algum tipo de limiar adaptativo em seus algoritmos. Isso pode ser encontrado nos algoritmos BEMD, BMCS e WAGA. A abordagem Topográfica, apesar de ser baseada no conceito de regiões concêntricas, também usa limiar no seu método. O problema envolvendo algoritmos baseados em limiar é que eles apresentam dificuldades em segmentar regiões com baixo contraste e especificamente lesões espiculadas e indefinidas, devido a valores próximos de intensidade entre massa e tecido. Técnicas baseadas em sementes, tais como o *GrowCut*, normalmente apresentam uma melhor segmentação para lesões espiculadas e indefinidas, mas dependem da seleção correta das sementes. A adição da função de pertinência *fuzzy* gaussiana reduz a necessidade de uma seleção precisa das sementes, mantendo a qualidade da segmentação. No entanto, é preciso que o centro de massa das sementes esteja dentro da região de lesão, o que acontece quando a maioria das sementes está localizada corretamente. O método não permite a localização totalmente incorreta, mas permite uma margem de erro maior do que os métodos do estado da arte.

Apesar de esse trabalho ter usado uma função gaussiana para mapear a região de lesão, outras funções podem ser implementadas para melhorar a qualidade dos resultados. Embora a região gaussiana não tenha um formato espiculado, ela foi capaz de fornecer uma boa estimativa para segmentação. O uso de funções de pertinência específicos para cada tipo de lesão também é possível. A geração automática de sementes também pode ser melhorada para lidar com imagens de mamografia com baixo contraste e com tecidos do tipo denso.

## 8 CONCLUSÃO E TRABALHOS FUTUROS

### 8.1 CONSIDERAÇÕES FINAIS

Neste trabalho foi proposta uma nova abordagem de segmentação de lesões de imagem de mamografia digital usando uma versão modificada, com lógica *fuzzy*, do algoritmo iterativo de segmentação GrowCut. Diferente do GrowCut clássico, em que o usuário tem que selecionar pontos internos e externos ao objeto de interesse a ser segmentado, a introdução da função de pertinência *fuzzy* Gaussiana permite que o usuário selecione apenas os pontos internos, tentando adicionar ao algoritmo proposto um nível de robustez e tolerância a falhas que não existe na abordagem original. Além disso, a fim de minimizar a necessidade da intervenção humana, foi utilizado o algoritmo de otimização Evolução Diferencial para selecionar automaticamente os pontos internos, definindo uma função de aptidão para guiar o processo para maximizar tanto a distância entre os pontos e o valor de intensidade total dos *pixels* selecionado. Essa função de aptidão permite a obtenção de pontos disjuntos localizados dentro da lesão mamária, que é que normalmente possui maior intensidade de *pixels* em relação aos tecidos vizinhos.

A abordagem proposta foi validada para as 57 imagens da base Mini-MIAS e 1.165 imagens da base IRMA. Resultados obtidos com o método proposto foram comparados com os seguintes métodos do estado da arte: BEMD, BMCS, MCW, abordagem Topográfica e WAGA. Foi realizada uma avaliação considerando o formato das bordas da lesão, para as bases Mini-MIAS e IRMA. Resultados para essas bases Mini-MIAS foram considerados muito bons para lesões do tipo espiculado e indefinido. Para o tipo de lesão circunscrita resultados foram considerados competitivos. Quando avaliado para a base Mini-MIAS, a técnica proposta mostrou melhores resultados, em geral, considerando lesões circunscritas e espiculadas, quando comparado com técnicas do estado da arte. Para a base de dados IRMA, foi aplicado um classificador para avaliar a qualidade da segmentação através da extração das características das imagens segmentadas, usando momentos de Zernike. Resultados mostraram que o algoritmo de segmentação semi-supervisionado proposto, *Fuzzy* GrowCut, pode ser considerado viável e adequado para segmentar lesões em imagens de mamografia digital.

A principal contribuição desse trabalho consiste na modificação da regra de evolução do autômato celular do GrowCut, introduzindo a função de pertinência *fuzzy* Gaussiana. O uso da função Gaussiana combinada com a regra de evolução do autômato celular elimina a necessidade da seleção de sementes externas ao objeto de interesse, o que não é visto em técnicas do estado da arte, além de manter a qualidade da segmentação.

Este trabalho também contribui com uma versão do GrowCut mais tolerante à

falhas, visto que apenas os pontos internos são selecionados e usados para na função de pertinência para realizar a segmentação. Além disso, a proposta é baseada no centro de massa dos pontos selecionados, tornando o método mais robusto.

Resultados podem ser estendidos a outras bases de dados de imagem de mamografia digital no caso de as imagens ouro poderem ser obtidas, a fim de avaliar o desempenho do algoritmo de segmentação semi-supervisionado proposto. No entanto, esta é uma tarefa difícil, uma vez que é necessário um esforço considerável para reunir uma equipe de especialistas de saúde a fim de construir um conjunto de imagens ouro confiável.

Apesar de o algoritmo de segmentação ter sido desenvolvido apenas para o problema de segmentação de lesões em mamogramas, este não é o único problema que o método que o *Fuzzy* GrowCut semi-supervisionado pode ser aplicado. Outras aplicações de análise de imagens biomédicas, especialmente aquelas baseadas em tomografia computadorizada de raio-x e imageamento por ressonância magnética, podem ser utilizar o método proposto, devido à similaridade com imagens de mamografia. O método proposto pode ser aplicado especialmente para imagens cuja segmentação do objeto de interesse com bordas complexas seja fundamental para obter um diagnóstico viável, tais como a detecção de nódulos no pulmão, segmentação do pâncreas e medição de matéria cinzenta em imagens de ressonância magnética.

## 8.2 CONTRIBUIÇÕES

A seguir seguem as principais contribuições realizadas com este trabalho:

- Desenvolvimento de uma modificação do algoritmo de propósito geral GrowCut para segmentar lesões em imagens de mamografia digital;
- Proposta de uma nova regra de evolução de autômato celular introduzindo função de pertinência *fuzzy* Gaussiana;
- Modelo de segmentação tolerante a falhas, uma vez que apenas os pontos internos são selecionados e usados para compor uma função de pertinência, usada para estabelecer os limites da segmentação;
- Modelo baseado em sementes com auxílio na redução de esforço especialista, uma vez que é necessário apenas a seleção dos pontos internos da região de interesse.
- Automatização da etapa de seleção de sementes, utilizado Evolução Diferencial;
- Desenvolvimento de um modelo adaptativo do algoritmo proposto cujas configurações de parâmetros são baseadas nas características da imagem;

O método *Fuzzy GrowCut* contribui na redução do esforço necessário para o posicionamento das sementes iniciais, reduzindo a quantidade de sementes necessárias e permitindo flexibilidade quanto a localização inicial. É importante ressaltar que o trabalho não tem como intuito a substituição do especialista pelo método de segmentação, mas sim fornecer uma ferramenta de auxílio ao diagnóstico, permitindo a identificação de regiões de lesões em imagens complexas.

A adição de um modelo tolerante à falhas facilita o processo de automatização de sementes, pois reduz o peso quanto à posição inicial das sementes geradas, permitindo que a etapa automática tenha mais flexibilidade quanto à localização de pontos. No entanto, o centro de massa das sementes obtidas necessita estar dentro da região de lesão.

Apesar da contribuição da utilização do modelo *fuzzy* gaussiano ter sido utilizado no *GrowCut*, ela pode ser expandida para outros algoritmos de segmentação. Desta forma, a contribuição não é apenas em uma modificação do *GrowCut* clássico, mas sim na proposta de um modelo de segmentação que reduz o esforço de inicialização e é robusto quanto ao posicionamento das sementes. Desta forma, a contribuição pode ser aplicado a outros métodos e utilizado para segmentar outros tipos de imagens.

### 8.3 PUBLICAÇÕES DO TRABALHO

- Conferência Intelligent Data Engineering and Automated Learning - (IDEAL) (CORDEIRO et al., 2012);
- Periódico Studies in Health Technology and Informatics (CORDEIRO; SANTOS; SILVA-FILHO, 2013);
- Artigo aceito para publicação no periódico *Applied Soft Computing*, com o trabalho intitulado *An Adaptive Semi-Supervised Fuzzy GrowCut Algorithm to Segment Masses of Regions of Interest of Mammographic Images*;
- Artigo aceito para publicação no periódico *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, com o trabalho intitulado *Analysis of Supervised and Semi-Supervised GrowCut applied to segmentation of masses in mammography images*;
- Proposta de capítulo de livro aceito para o livro intitulado *Hybrid Soft Computing for Image Segmentation*, a ser publicado pela Springer.

### 8.4 PUBLICAÇÕES RELACIONADAS

- Artigo intitulado *Fuzzy Morphological Extreme Learning Machines to Detect and Classify Masses in Mammograms*, publicado para a conferência *IEEE International*

*Conference on Fuzzy Systems* (AZEVEDO et al., 2015b).

- Artigo intitulado *Morphological Extreme Learning Machines Applied to Detect and Classify Masses in Mammograms*, publicado na conferência *International Joint Conference on Neural Networks* (IJCNN) (AZEVEDO et al., 2015a).

## 8.5 TRABALHOS FUTUROS

Além das contribuições geradas a partir desse trabalho, algumas linhas de pesquisas podem ser seguidas a partir do algoritmo proposto. Trabalhos futuros para a pesquisa desenvolvida envolvem a melhoria do tempo de simulação do algoritmo proposto, através da implementação em hardware do *Fuzzy GrowCut* e análise do ganho de desempenho. Uma vez que o algoritmo proposto é baseado em autômatos celulares, o processo de paralelização pode ser realizado com eficiência.

Pretendemos também tornar o método não supervisionado, onde a partir da imagem original de mamografia digital seja realizada a segmentação da lesão, sem a intervenção do especialista. Para isto, será necessário a escolha de um método não supervisionado para a seleção da região de interesse, o que associado com o *Fuzzy GrowCut* permitirá a realização da segmentação a partir da imagem original. Apesar do método vir a ser não supervisionado, o objetivo é que seja uma ferramenta de apoio ao especialista para auxiliar na tomada de decisões.

Devido ao fato do *GrowCut* ser um algoritmo de propósito geral, a sua versão modifica também pode ser viável para segmentar outros tipos de imagens, sejam imagens médicas, em tons de cinza, ou coloridas. Desta forma, temos como objetivo analisar o FGC para segmentação de outros tipos de imagens médicas, comparando com técnicas do estado da arte. Apesar das dificuldades envolvidas, desejamos buscar a validação dos resultados obtidos neste trabalho e em trabalhos futuros junto à profissionais da área médica.

Visto que a maior contribuição do trabalho está na adição de uma abordagem *fuzzy* gaussiana em um algoritmo de segmentação baseada em sementes, temos como meta expandir esse estudo e realizar modificações em outros algoritmos de segmentação, tais como *Random Walks* e *Graph Cuts*. Essa abordagem permite a flexibilidade quanto à marcação do especialista, pois possibilita menor variância na segmentação final entre diferentes usuários.

Em trabalhos futuros também pretendemos utilizar funções de pertinência específicas para lesões do tipo espiculado e indefinido, pois são os tipos de lesão que as técnicas do estado da arte apresentam maior dificuldade para realizar a segmentação. Devido ao fato da região gaussiana possuir formato similar à regiões de lesão do tipo circunscrito, ela consegue se aproximar melhor da região, gerando melhores resultados. Utilizando-se

funções de pertinência próprias para lesões do tipo espiculado, espera-se obter melhores resultados para esses casos.

Temos como objetivo também testar outros algoritmos de classificação, tais como SVM e Redes Bayesianas, para verificar a taxa de classificação obtida a partir da segmentação dos métodos do estado da arte, a fim de validar a qualidade da segmentação.

Outra melhoria futura a ser realizada no FGC é quanto à necessidade do centro de massa estar dentro da região de lesão. Serão feitos estudos para aumentar ainda mais a tolerância à falhas do algoritmo.

Para a geração automática de sementes, serão aplicados outros algoritmos de otimização, tais como algoritmos genéticos ou algoritmos baseados em enxame de partículas, a fim de otimizar a geração das sementes.

Com as imagens ouro obtidas durante esse trabalho para a base IRMA, pretendemos publicar e disponibilizar a base de imagens ouro para estudo e análise em trabalhos futuros.

## Referências

- ABREU, E. D.; KOIFMAN, S. Fatores prognósticos no câncer da mama feminina. *Revista Brasileira de Cancerologia*, Rio de Janeiro, v. 48, n. 1, p. 113–131, 2002.
- AGHDAM, H. H.; PUIG, D.; SOLANAS, A. A probabilistic approach for breast boundary extraction in mammograms. *Computational and Mathematical Methods in Medicine*, Hindawi Publishing Corporation, v. 2013, 2013.
- AL-NAJDAWI, N.; BILTAWI, M.; TEDMORI, S. Mammogram image visual enhancement, mass segmentation and classification. *Applied Soft Computing*, v. 35, p. 175–185, out. 2015.
- ALI, M.; SIARRY, P.; PANT, M. An efficient differential evolution based algorithm for solving multi-objective optimization problems. *European Journal of Operational Research*, Elsevier, v. 217, n. 2, p. 404–416, 2012.
- ALPAYDIN, E. *Introduction to machine learning*. Londres: MIT press, 2014.
- ANDREWS, S.; HAMARNEH, G.; SAAD, A. *Fast Random Walker with Priors Using Precomputation for Interactive Medical Image Segmentation*. Springer, 2010. Disponível em: <[http://link.springer.com/chapter/10.1007/978-3-642-15711-0\\_2](http://link.springer.com/chapter/10.1007/978-3-642-15711-0_2)>. Acesso em: 01 jan. 2016.
- ANITHA, J.; PETER, J. D. A wavelet based morphological mass detection and classification in mammograms. In: IEEE. *Machine Vision and Image Processing (MVIP), 2012 International Conference on*. Taipei, 2012. p. 25–28.
- ARAÚJO, A. P. *Megapixels*. InfoEscola, 2015. Disponível em: <<http://www.infoescola.com/fotografia/megapixels/>>. Acesso em: 01 jan. 2016.
- ASCANEO, J. S. *Segmentação de Imagens Utilizando Passeios Aleatórios em Grafos*. Dissertação (Mestrado em Matemática) — Instituto de Matemática e Estatística, Universidade de São Paulo, 2012.
- ASHBY, A. E. et al. Ucsf/llnl high resolution digital mammogram library. In: IEEE. *Engineering in Medicine and Biology Society, 1995., IEEE 17th Annual Conference*. [S.l.], 1995. v. 1, p. 539–540.
- AUTIER, P. et al. Advanced breast cancer incidence following population-based mammographic screening. *Annals of Oncology*, Eur Soc Med Oncology, p. 600–633, 2011.
- AZEVEDO, W. et al. Morphological extreme learning machines applied to detect and classify masses in mammograms. In: *Neural Networks (IJCNN), 2015 International Joint Conference on*. Killarney: [s.n.], 2015. p. 1–8.
- AZEVEDO, W. W. et al. Fuzzy morphological extreme learning machines to detect and classify masses in mammograms. In: IEEE. *Fuzzy Systems (FUZZ-IEEE), 2015 IEEE International Conference on*. Istanbul, 2015. p. 1–8.

- BANDEIRA, D. et al. Repercussões da mastectomia nas esferas pessoal, social e familiar para a mulher mastectomizada: Uma Revisão. *Revista Contexto & Saúde*, Ijuí, v. 10, n. 20, p. 473–482, 2011.
- BELTRÃO-BRAGA, P. C.; TEIXEIRA, V. R.; CHAMMAS, R. Aspectos moleculares da transformação celular: conceitos e implicações. *Revista Brasileira de Cancerologia*, Atheneu, v. 1, n. 1, p. 113–131, 2002.
- BERBER, T. et al. Breast mass contour segmentation algorithm in digital mammograms. *Computer methods and programs in biomedicine*, Elsevier, v. 110, n. 2, p. 150–159, 2013.
- BEROALDO JUREMA. *Mamografia Digital e Digitalizada*. 2015. Disponível em: <<http://www.beroaldojurema.com.br/mamografiadigital.html>>. Acesso em: 01 jan. 2016.
- BHATEJA, V. et al. Improvement of masses detection in digital mammograms employing non-linear filtering. *Automation, Computing, Communication, Control and Compressed Sensing (iMac4s), 2013 International Multi-Conference on*, p. 406–408, 2013.
- BILTAWI, M.; AL-NAJDAWI, N.; TEDMORI, S. Mammogram enhancement and segmentation methods: classification, analysis, and evaluation. In: *The 13th international Arab conference on information technology*. [S.l.: s.n.], 2012.
- BLEAU, A.; LEON, L. J. Watershed-based segmentation and region merging. *Computer Vision and Image Understanding*, Elsevier, v. 77, n. 3, p. 317–370, 2000.
- CHAKRABORTY, J. et al. Detection of masses in mammograms using region growing controlled by multilevel thresholding. In: IEEE. *Computer-Based Medical Systems (CBMS), 2012 25th International Symposium on*. Roma, 2012. p. 1–6.
- CHAMBERS, L. D. *Practical Handbook of Genetic Algorithms: Complex Coding Systems*. [S.l.]: CRC press, 2010. v. 3.
- CHAN, T. F.; VESE, L. A. Active contours without edges. *Image Processing, IEEE Transactions on*, IEEE, v. 10, n. 2, p. 266–277, 2001.
- CHAPELLE, O. et al. Semi-supervised learning. MIT press Cambridge, 2006.
- CHEN, Z.; ZWIGGELAAR, R. Segmentation of the breast region with pectoral muscle removal in mammograms. *Medical Image Understanding and Analysis (MIUA)*, p. 71–76, 2010.
- CHENG, H. et al. Approaches for automated detection and classification of masses in mammograms. *Pattern recognition*, Elsevier, v. 39, n. 4, p. 646–668, 2006.
- CIESIELSKI, K. C. et al. Joint graph cut and relative fuzzy connectedness image segmentation algorithm. *Medical image analysis*, Elsevier, v. 17, n. 8, p. 1046–1057, 2013.
- CORDEIRO, F. R. et al. Segmentation of mammography by applying extreme learning machine in tumor detection. In: *Intelligent Data Engineering and Automated Learning-IDEAL 2012*. [S.l.]: Springer, 2012. p. 92–100.
- CORDEIRO, F. R.; SANTOS, W. P.; SILVA-FILHO, A. G. Segmentation of mammography by applying growcut for mass detection. *Studies in Health Technology and Informatics*, v. 192, n. 1-2, p. 87–91, 2013.

- CORDEIRO, F. R.; SANTOS, W. P.; SILVA-FILHOA, A. G. Segmentation of mammography by applying growcut for mass detection. *women*, v. 1, p. 3, 2013.
- CZAPLICKA, K.; WŁODARCZYK, J. Automatic breast-line and pectoral muscle segmentation. *Schedae Informaticae*, v. 20, p. 195–209, 2011.
- DAS, S.; SUGANTHAN, P. N. Differential evolution: A survey of the state-of-the-art. *Evolutionary Computation, IEEE Transactions on*, IEEE, v. 15, n. 1, p. 4–31, 2011.
- DASGUPTA, D.; MICHALEWICZ, Z. *Evolutionary algorithms in engineering applications*. Nova York: Springer Science & Business Media, 2013.
- DEB, K. Multi-objective optimization. In: *Search methodologies*. [S.l.]: Springer, 2014. p. 403–449.
- DESANTIS, C. E. et al. Cancer treatment and survivorship statistics, 2014. *CA: a cancer journal for clinicians*, Wiley Online Library, v. 64, n. 4, p. 252–271, 2014.
- DESERNO, T. M. et al. Computer-aided diagnostics of screening mammography using content-based image retrieval. *SPIE Medical Imaging*, p. 831527–831527, 2012.
- DESERNO, T. M. et al. Towards computer-aided diagnostics of screening mammography using content-based image retrieval. *Graphics, Patterns and Images (Sibgrapi), 2011 24th SIBGRAPI Conference on*, p. 211–219, 2011.
- DHALIWAL, S.; JAIN, A. A survey on seeded region growing based segmentation algorithms. *International Journal of Computer Science and Management Research*, v. 2, n. 6, 2013.
- DHEEBA, J.; SINGH, N. A.; SELVI, S. T. Computer-aided detection of breast cancer on mammograms: A swarm intelligence optimized wavelet neural network approach. *Journal of Biomedical Informatics*, Elsevier, v. 49, p. 45–52, 2014.
- D’ORSI, C. J. et al. *Breast Imaging Reporting and Data System:(BI-RADS)*. [S.l.]: American College of Radiology, 1998.
- DOWSLAND, K. A.; THOMPSON, J. M. Simulated annealing. In: *Handbook of Natural Computing*. [S.l.]: Springer, 2012. p. 1623–1655.
- ELTOUKHY, M. M.; FAYE, I. An adaptive threshold method for mass detection in mammographic images. In: IEEE. *Signal and Image Processing Applications (ICSIPA), 2013 IEEE International Conference on*. [S.l.], 2013. p. 374–378.
- ELYOR, K.; LEE, G. Automatic object segmentation using mean shift and growcut. *The 19th Korea-Japan Joint Workshop on Frontiers of Computer Vision*, p. 184–189, 2013.
- ESENER, I. I.; ERGIN, S.; YUKSEL, T. A new ensemble of features for breast cancer diagnosis. In: IEEE. *Information and Communication Technology, Electronics and Microelectronics (MIPRO), 2015 38th International Convention on*. [S.l.], 2015. p. 1168–1173.
- EVANS, K. K.; BIRDWELL, R. L.; WOLFE, J. M. If you don’t find it often, you often don’t find it: Why some cancers are missed in breast cancer screening. *PloS one*, Public Library of Science, v. 8, n. 5, p. 364–366, 2013.

- FENTON, J. J. et al. Effectiveness of computer-aided detection in community mammography practice. *Journal of the National Cancer Institute*, Oxford University Press, 2011.
- FERNANDES, I.; SANTOS, W. dos. Classificação de mamografias utilizando extração de atributos de textura e redes neurais artificiais. *Congresso Brasileiro de Engenharia Biomédica*, p. 8, 2014.
- FRIENDLY, M. et al. Elliptical insights: understanding statistical methods through elliptical geometry. *Statistical Science*, Institute of Mathematical Statistics, v. 28, n. 1, p. 1–39, 2013.
- FURQUIM, T. A. C. 10 programas de garantia de qualidade em mamografia. *MINISTÉRIO DA SAÚDE*, p. 143, 2014.
- GAO, X. et al. On combining morphological component analysis and concentric morphology model for mammographic mass detection. *Information Technology in Biomedicine, IEEE Transactions on*, IEEE, v. 14, n. 2, p. 266–273, 2010.
- GONZALEZ, R. C.; WOODS, R. E.; EDDINS, S. L. *Digital image processing using MATLAB*. [S.l.]: Gatesmark Publishing Knoxville, 2009. v. 2.
- GORDILLO, N.; MONTSENY, E.; SOBREVILLA, P. State of the art survey on MRI brain tumor segmentation. *Magnetic Resonance Imaging*, Elsevier Inc., v. 31, n. 8, p. 1426–1438, 2013.
- GORGEL, P. et al. Mammographic mass classification using wavelet based support vector machine. *IU-Journal of Electrical & Electronics Engineering*, v. 9, n. 1, p. 867–875, 2012.
- GRADY, L. Random walks for image segmentation. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, IEEE, v. 28, n. 11, p. 1768–1783, 2006.
- HAMAMCI, A. et al. Tumor-cut: Segmentation of brain tumors on contrast enhanced mr images for radiosurgery applications. *IEEE Transactions on Medical Imaging*, v. 31, n. 3, p. 790–804, 2012.
- HAMMOUCHE, K.; DIAF, M.; SIARRY, P. A multilevel automatic thresholding method based on a genetic algorithm for a fast image segmentation. *Computer Vision and Image Understanding*, Elsevier, v. 109, n. 2, p. 163–175, 2008.
- HAN, Z.-z. et al. A novel method of mass segmentation in mammogram. In: IEEE. *Systems and Informatics (ICSAI), 2012 International Conference on*. [S.l.], 2012. p. 1412–1416.
- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. H. Textural features for image classification. *Systems, Man and Cybernetics, IEEE Transactions on*, IEEE, n. 6, p. 610–621, 1973.
- HARFORD, J. B. Breast-cancer early detection in low-income and middle-income countries: do what you can versus one size fits all. *The lancet oncology*, Elsevier, v. 12, n. 3, p. 306–312, 2011.

- HEATH, M. et al. The digital database for screening mammography. In: CITESEER. *Proceedings of the 5th international workshop on digital mammography*. [S.l.], 2000. p. 212–218.
- HERNANDEZ, G.; HERRMANN, H. J. Cellular automata for elementary image enhancement. *Graphical Models and Image Processing*, Elsevier, v. 58, n. 1, p. 82–89, 1996.
- HONG, B.-W.; SOHN, B.-S. Segmentation of regions of interest in mammograms in a topographic approach. *Information Technology in Biomedicine, IEEE Transactions on*, v. 14, n. 1, p. 129–139, Jan 2010. ISSN 1089-7771.
- HUANG, N. E. et al. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis. In: THE ROYAL SOCIETY. *Proceedings of the Royal Society of London A: Mathematical, Physical and Engineering Sciences*. [S.l.], 1998. v. 454, n. 1971, p. 903–995.
- IMAX DIGITAL. *Mamografia Digital*. 2012. Disponível em: <[http://www.clinicaimax.com.br/?page\\_id=31](http://www.clinicaimax.com.br/?page_id=31)>. Acesso em: 01 jan. 2016.
- INCA. *Falando sobre câncer de mama*. 2002. Disponível em: <<http://www.inca.gov.br/estimativa/2014/estimativa-24042014.pdf>>. Acesso em: 01 jan. 2016.
- INCA. *Estimativa Incidência de câncer no Brasil*. [S.l.: s.n.], 2014. v. 1. 124 p. ISBN 9788573182361.
- JAI-ANDALOUSSI, S. et al. Mass segmentation in mammograms by using bidimensional empirical mode decomposition bemd. *Engineering in Medicine and Biology Society (EMBC), 2013 35th Annual International Conference of the IEEE*, p. 5441–5444, 2013.
- JAIN, A.; SINGH, S.; BHATEJA, V. A robust approach for denoising and enhancement of mammographic images contaminated with high density impulse noise. *International Journal of Convergence Computing*, Inderscience, v. 1, n. 1, p. 38–49, 2013.
- JENIFER, S.; PARASURAMAN, S.; KADIRVEL, A. An efficient biomedical imaging technique for automatic detection of abnormalities in digital mammograms. *Journal of Medical Imaging and Health Informatics*, American Scientific Publishers, v. 4, n. 2, p. 291–296, 2014.
- JIFI, G. W.; MARSILIN, J. R. Localization of Tumor and its Stage using Intelligent Techniques. *Applied Soft Computing*, v. 27, p. 468–473, fev. 2015. ISSN 15684946.
- KARABATAK, M. A new classifier for breast cancer detection based on naïve bayesian. *Measurement*, Elsevier, v. 72, p. 32–36, 2015.
- KARAHALIOU, A. et al. Texture analysis of tissue surrounding microcalcifications on mammograms for breast cancer diagnosis. *The British Journal of Radiology*, British Institute of Radiology, 2014.
- KARLIK, B.; OLGAC, A. V. Performance analysis of various activation functions in generalized mlp architectures of neural networks. *International Journal of Artificial Intelligence and Expert Systems*, v. 1, n. 4, p. 111–122, 2011.
- KASS, M.; WITKIN, A.; TERZOPOULOS, D. Snakes: Active contour models. *International journal of computer vision*, Springer, v. 1, n. 4, p. 321–331, 1988.

- KOLMOGOROV, V.; ZABIN, R. What energy functions can be minimized via graph cuts? *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, IEEE, v. 26, n. 2, p. 147–159, 2004.
- KRUSE, R. et al. Multi-layer perceptrons. In: *Computational Intelligence*. [S.l.]: Springer, 2013. p. 47–81.
- LANKTON, S. *GrowCut Image Segmentation for binary segmentation, implemented in Matlab/C++ with mex*. 2008. Disponível em: <<http://www.mathworks.com/matlabcentral/fileexchange/19091-growcut-image-segmentation>>. Acesso em: 01 jan. 2016.
- LEVINE, D. S.; IV, M. A. *Neural Networks for Knowledge Representation and Inference*. [S.l.]: Psychology Press, 2013.
- LEWIS, S. H.; DONG, A. Detection of breast tumor candidates using marker-controlled watershed segmentation and morphological analysis. In: IEEE. *Image Analysis and Interpretation (SSIAI), 2012 IEEE Southwest Symposium on*. [S.l.], 2012. p. 1–4.
- LI, D. et al. An edge embedded marker-based watershed algorithm for high spatial resolution remote sensing image segmentation. *Image Processing, IEEE Transactions on*, IEEE, v. 19, n. 10, p. 2781–2787, 2010.
- LIBERMAN, L.; MENELL, J. H. Breast imaging reporting and data system (BI-RADS). *Radiologic Clinics of North America*, v. 40, p. 409–430, 2002. ISSN 00338389.
- LIFSHITS, M. A. *Gaussian random functions*. [S.l.]: Springer Science & Business Media, 2013. v. 322.
- LIMA, S. M. L. de. *Ferramenta Computacional para Auxílio ao Diagnóstico em Imagens de Câncer de Mama*. 2011. Dissertação (Mestrado em Engenharia da Computação) - Universidade de Pernambuco. 2011.
- LIU, F. et al. A fully automated scheme for mass detection and segmentation in mammograms. In: IEEE. *Biomedical Engineering and Informatics (BMEI), 2012 5th International Conference on*. [S.l.], 2012. p. 140–144.
- LIU, X. et al. A new automatic method for mass detection in mammography with false positives reduction by supported vector machine. In: IEEE. *Biomedical Engineering and Informatics (BMEI), 2011 4th International Conference on*. [S.l.], 2011. v. 1, p. 33–37.
- LU, H.; CHEN, J. Research of color image segmentation based on improved growcut algorithm. *Journal of Computational Information Systems*, v. 10, n. 21, p. 9057–9066, 2014.
- MARQUES, C. A. V.; GUTIÉRREZ, M. G. R. de; FIGUEIREDO, E. N. de. Políticas de saúde pública para o controle do câncer de mama no brasil. *Revista Enfermagem UERJ*, v. 23, n. 2, p. 272–278, 2015.
- MATHENGE, E. G. et al. Core needle biopsy of breast cancer tumors increases distant metastases in a mouse model. *Neoplasia*, Elsevier, v. 16, n. 11, p. 950–960, 2014.
- MATLAB. *MathWorks*. 2011. Disponível em: <<http://www.mathworks.com/>>. Acesso em: 01 jan. 2016.

- MEDEIROS, R. M. et al. Câncer de mama: Análise situacional em uma cidade do norte do rio grande do sul. *Inova Saúde*, v. 2, n. 2, 2014.
- MINEO, F. V. et al. Assistência de enfermagem no tratamento do câncer de mama. *Gestão e Saúde*, v. 4, n. 2, p. pag-366, 2013.
- MOHAMED, S.; BEHIELS, G.; DEWAELE, P. Mass candidate detection and segmentation in digitized mammograms. In: IEEE. *Science and Technology for Humanity (TIC-STH), 2009 IEEE Toronto International Conference*. [S.l.], 2009. p. 557-562.
- MONTEIRO, F.; SIQUEIRA, P. Correlação entre o exame clínico, a mamografia e a ultra-sonografia com o exame anatomopatológico na determinação do tamanho tumoral no câncer de mama. *Rev Bras Ginecol Obstet*, SciELO Brasil, v. 30, n. 3, p. 107-12, 2008.
- MUŠTRA, M.; GRGIĆ, M.; DELAČ, K. Breast density classification using multiple feature selection. *AUTOMATIKA: časopis za automatiku, mjerenje, elektroniku, računarstvo i komunikacije*, KoREMA-Hrvatsko društvo za komunikacije, računarstvo, elektroniku, mjerenja i automatiku, v. 53, n. 4, p. 362-372, 2012.
- NAYAK, D. R. et al. A survey on two dimensional cellular automata and its application in image processing. *Proceedings on International Conference on Emergent Trends in Computing and Communication (ETCC-2014)*, n. 1, p. 78-87, 2014.
- NEVES, S. C. M.; PELAES, E. G.; SINAIS, L. d. P. de. Estudo e implementação de técnicas de segmentação de imagens. *Revista Virtual de Iniciação Acadêmica da UFPA-Universidade Federal do Pará-Departamento de Engenharia Elétrica e de Computação*, v. 1, n. 2, 2008.
- NEVLAND, D. E. *An Introduction to Random Vibrations, Spectral & Wavelet Analysis*. [S.l.]: Courier Dover Publications, 2012.
- NOVIKOV, I. I.; PROTASOV, V. I.; SKOPINA, M. A. *Wavelet Theory*. [S.l.]: American Mathematical Soc., 2011. v. 239.
- NUNES, J. C. et al. Image analysis by bidimensional empirical mode decomposition. *Image and vision computing*, Elsevier, v. 21, n. 12, p. 1019-1026, 2003.
- OLIVEIRA, J. E. D. et al. Mammosys: A content-based image retrieval system using breast density patterns. *Computer methods and programs in biomedicine*, Elsevier, v. 99, n. 3, p. 289-297, 2010.
- ORGANIZATION, W. H. et al. *WHO position paper on mammography screening*. [S.l.]: World Health Organization, 2014.
- PAPARI, G.; PETKOV, N. Edge and line oriented contour detection: State of the art. *Image and Vision Computing*, Elsevier, v. 29, n. 2, p. 79-103, 2011.
- PATIL, D. D.; DEORE, S. G. Medical image segmentation: A review. *International Journal of Computer Science and Mobile Computing*, v. 2, n. 1, p. 22-27, 2013.
- PEREIRA, D. C.; RAMOS, R. P.; NASCIMENTO, M. Z. D. Segmentation and detection of breast cancer in mammograms combining wavelet analysis and genetic algorithm. *Computer methods and programs in biomedicine*, Elsevier, v. 114, n. 1, p. 88-101, 2014.

- PHAN, R.; ANDROUTSOS, D. Interactive video growcut: A semi-automated video object segmentation framework using cellular automata. In: IEEE. *Electrical and Computer Engineering (CCECE), 2011 24th Canadian Conference on*. [S.l.], 2011. p. 81–84.
- PIETIKÄINEN, M. et al. *Computer vision using local binary patterns*. [S.l.]: Springer, 2011. v. 40.
- PINHEIRO, P. *O que é Câncer?* 2014. Disponível em: <<http://www.mdsaude.com/2009/02/cancer-cancro-sintomas.html>>. Acesso em: 01 jan. 2016.
- PRICE, K.; STORN, R. M.; LAMPINEN, J. A. Differential Evolution: A Practical Approach to Global Optimization (Natural Computing Series). *The Journal of heredity*, v. 104, p. 542, 2005. ISSN 1465-7333.
- RABOTTINO, G. et al. Performance evaluation of a region growing procedure for mammographic breast lesion identification. *Computer Standards & Interfaces*, Elsevier, v. 33, n. 2, p. 128–135, 2011.
- RAHMATI, P.; ADLER, A.; HAMARNEH, G. Mammography segmentation with maximum likelihood active contours. *Medical image analysis*, Elsevier, v. 16, n. 6, p. 1167–1186, 2012.
- RAHMATI, P. et al. A new preprocessing filter for digital mammograms. In: *Image and Signal Processing*. [S.l.]: Springer, 2010. p. 585–592.
- RAJASEKARAN, S.; PAI, G. V. *Neural Networks, Fuzzy Logic and Genetic Algorithms*. [S.l.]: PHI Learning Private Limited, 2011.
- RAMAN, V. et al. Review on mammogram mass detection by machine learning techniques. *International Journal of Computer and Electrical Engineering*, v. 3, n. 6, p. 873–879, 2011.
- RUSSELL, S.; NORVIG, P. *Artificial Intelligence: A Modern Approach*. [S.l.]: Prentice Hall, 2003. v. 60. 269–72 p. (Prentice Hall Series In Artificial Intelligence, 4). ISSN 00206539. ISBN 0137903952.
- SAIDIN, N. et al. Computer aided detection of breast density and mass, and visualization of other breast anatomical regions on mammograms using graph cuts. *Computational and mathematical methods in medicine*, Hindawi Publishing Corporation, v. 2013, 2013.
- SAMUELS, M. L.; WITMER, J. A.; SCHAFFNER, A. *Statistics for the Life Sciences*. [S.l.]: Pearson education, 2012.
- SHAO, H. et al. Comparison of the diagnostic efficiency for breast cancer in chinese women using mammography, ultrasound, mri, and different combinations of these imaging modalities. *Journal of X-ray science and technology*, IOS Press, v. 21, n. 2, p. 283–292, 2013.
- SHARMA, S.; KHANNA, P. Roi segmentation using local binary image. In: IEEE. *Control System, Computing and Engineering (ICCSCE), 2013 IEEE International Conference on*. [S.l.], 2013. p. 136–141.
- SHARMA, S.; KHANNA, P. Computer-aided diagnosis of malignant mammograms using zernike moments and svm. *Journal of digital imaging*, Springer, v. 28, n. 1, p. 77–90, 2015.

- SICKLES, E. A.; KUBIK-HUCH, R. A.; MÜLLER-SCHIMPFLE, M. Imaging breast disease: Mammography and breast ultrasound. In: *Diseases of the Heart and Chest, Including Breast 2011–2014*. [S.l.]: Springer, 2011. p. 184–190.
- SONG, H. et al. Kidney segmentation in CT sequences using SKFCM and improved GrowCut algorithm. *BMC Systems Biology*, BioMed Central Ltd, v. 9, n. 5, p. 55, 2015. ISSN 1752-0509.
- SONG, L. et al. Segmentation of breast masses using adaptive region growing. *Strategic Technology (IFOST), 2013 8th International Forum on*, v. 2, p. 77–81, 2013.
- STEINWART, I.; CHRISTMANN, A. *Support Vector Machines*. [S.l.]: Springer, 2008.
- SUCKLING, J. et al. The mammographic image analysis society digital mammogram database. In: *Excerpta Medica. International Congress Series*. [S.l.: s.n.], 1994. v. 1069, p. 375–378.
- SUNDARAM, M. et al. Histogram Modified Local Contrast Enhancement for mammogram images. *Applied Soft Computing*, v. 11, n. 8, p. 5809–5816, dez. 2011. ISSN 15684946.
- TAHMASBI, A.; SAKI, F.; SHOKOUHI, S. B. Classification of benign and malignant masses based on zernike moments. *Computers in Biology and Medicine*, Elsevier, v. 41, n. 8, p. 726–735, 2011.
- TEIXEIRA, M. d. B. R. *Avaliação dos Achados Mamográficos Classificados na Categoria 4 do Sistema BI\_RADS® e sua Correlação Histopatológica*. Dissertação (Mestrado) — Universidade Estadual Paulista (UNESP), 2011.
- TORTAJADA, M. et al. Breast peripheral area correction in digital mammograms. *Computers in biology and medicine*, Elsevier, v. 50, p. 32–40, 2014.
- TORTORA, G. J.; DERRICKSON, B. *Corpo Humano: Fundamentos de Anatomia e Fisiologia*. [S.l.]: ArtMed, 2012.
- TOUDJEU, I. T. et al. Global image feature extraction using slope pattern spectra. In: *Image Analysis and Recognition*. [S.l.]: Springer, 2008. p. 640–649.
- TUNALI, I.; KILIC, E. Mass segmentation on mammograms using active contours. In: IEEE. *Signal Processing and Communications Applications Conference (SIU), 2013 21st*. [S.l.], 2013. p. 1–4.
- VEERARAGHAVAN, H.; MILLER, J. V. Active learning guided interactions for consistent image segmentation with reduced user interactions. In: IEEE. *Biomedical Imaging: From Nano to Macro, 2011 IEEE International Symposium on*. [S.l.], 2011. p. 1645–1648.
- VEZHNEVETS, V.; KONOUCHINE, V. GrowCut - Interactive Multi-Label N-D Image Segmentation By Cellular Automata. *Graphicon*, p. 150–156, 2005. ISSN 08895406.
- VICENTE, S.; KOLMOGOROV, V.; ROTHER, C. Graph cut based image segmentation with connectivity priors. In: IEEE. *Computer Vision and Pattern Recognition, 2008. CVPR 2008. IEEE Conference on*. [S.l.], 2008. p. 1–8.

- WANG, F.; LANDAU, D. P. Efficient, multiple-range random walk algorithm to calculate the eensity of states. *Physical Review Letters*, APS, v. 86, n. 10, p. 2050, 2001.
- WANG, W.; MOTTERSHEAD, J. E.; MARES, C. Mode-shape recognition and finite element model updating using the zernike moment descriptor. *Mechanical Systems and Signal Processing*, Elsevier, v. 23, n. 7, p. 2088–2112, 2009.
- WHO. Latest world cancer statistics Global cancer burden rises to 14 . 1 million new cases in 2012 : Marked increase in breast cancers must be addressed. *International Agency for Research on Cancer, World Health Organization*, p. 2012–2014, 2013. Disponível em: <[http://www.iarc.fr/en/media-centre/pr/2013/pdfs/pr223\\\_E.pdf](http://www.iarc.fr/en/media-centre/pr/2013/pdfs/pr223\_E.pdf)>. Acesso em: 01 jan. 2016.
- WILAMOWSKI, B. M.; YU, H. Improved computation for levenberg–marquardt training. *Neural Networks, IEEE Transactions on*, IEEE, v. 21, n. 6, p. 930–937, 2010.
- WONGTHANAVASU, S. *Cellular automata for medical image processing*. [S.l.]: INTECH Open Access Publisher, 2011.
- WU, X. et al. An interactive segmentation method using graph cuts for mammographic masses. *Bioinformatics and Biomedical Engineering, (iCBBE) 2011 5th International Conference on*, p. 1–4, 2011.
- XU, S.; LIU, H.; SONG, E. Marker-controlled watershed for lesion segmentation in mammograms. *Journal of digital imaging*, Springer, v. 24, n. 5, p. 754–763, 2011.
- YAMASAKI, T. et al. Comparative study of interactive seed generation for growcut-based fast 3d mri segmentation. In: IEEE. *Signal & Information Processing Association Annual Summit and Conference (APSIPA ASC), 2012 Asia-Pacific*. [S.l.], 2012. p. 1–4.
- YASMIN, M.; MOHSIN, S.; SHARIF, M. Intelligent image retrieval techniques: A survey. *Journal of applied research and technology*, Elsevier, v. 12, n. 1, p. 87–103, 2014.
- ZEWEI, Z. et al. An interactive method based on the live wire for segmentation of the breast in mammography images. *Computational and mathematical methods in medicine*, Hindawi Publishing Corporation, v. 2014, 2014.
- ZHANG, Y. et al. A contour-based mass segmentation in mammograms. *SoC Research Symposium*, 2009.
- ZHAO, F.; XIE, X. An Overview of Interactive Medical Image Segmentation. *Annals of the BMVA*, v. 2013, n. 7, p. 1–22, 2013.
- ZHENG, S.-W.; LIU, J.; LIU, C.-C. A random-walk based breast tumors segmentation algorithm for mammograms. *Computer, Consumer and Control (IJ3C), International Journal on*, 2013.
- ZHOU, A. et al. Multiobjective evolutionary algorithms: A survey of the state of the art. *Swarm and Evolutionary Computation*, Elsevier, v. 1, n. 1, p. 32–49, 2011.
- ZHU, L. et al. An effective interactive medical image segmentation method using fast growcut. In: *MICCAI Workshop on Interactive Medical Image Computing*. [S.l.: s.n.], 2014.

## Apêndices

**APÊNDICE A – Análise de Parâmetros dos Algoritmos Implementados.**

**Tabela 42** – Análise dos Parâmetros da Técnica de Segmentação por Abordagem Topográfica, para a base Mini-MIAS.

NL	Prof.	$E_{\text{Área}}$	$E_{\text{FF}}$	$E_{\text{Per}}$	$E_{\text{FX}}$	$E_{\text{FY}}$	AOM	BAC
10	2	0,38±0,26	0,45±0,27	0,33±0,23	<b>0,24±0,18</b>	<b>0,26±0,23</b>	<b>0,51±0,22</b>	0,79±0,12
10	3	0,54±0,35	0,43±0,22	0,35±0,25	0,33±0,24	0,31±0,24	0,49±0,25	<b>0,81±0,12</b>
10	4	0,70±0,31	<b>0,41±0,24</b>	0,40±0,27	0,41±0,26	0,40±0,25	0,42±0,24	0,76±0,13
10	5	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
10	6	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
10	7	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
10	8	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
10	9	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
20	2	0,48±0,23	0,54±0,29	0,46±0,22	0,36±0,26	0,38±0,25	0,33±0,21	0,66±0,11
20	3	<b>0,36±0,24</b>	0,46±0,31	0,34±0,23	0,25±0,23	0,29±0,22	0,46±0,23	0,74±0,13
20	4	0,39±0,26	0,44±0,27	0,33±0,24	0,26±0,19	<b>0,26±0,23</b>	<b>0,51±0,22</b>	0,80±0,12
20	5	0,47±0,32	0,42±0,24	0,34±0,23	0,32±0,23	0,29±0,24	0,51±0,24	0,81±0,12
20	6	0,56±0,35	0,43±0,23	0,35±0,25	0,34±0,25	0,32±0,24	0,49±0,25	0,81±0,12
20	7	0,64±0,34	0,42±0,23	0,38±0,27	0,38±0,25	0,37±0,26	0,44±0,25	0,79±0,12
20	8	0,71±0,31	<b>0,41±0,24</b>	0,42±0,26	0,42±0,26	0,42±0,26	0,40±0,23	0,75±0,12
20	9	0,77±0,28	0,41±0,26	0,45±0,26	0,45±0,25	0,45±0,25	0,36±0,22	0,71±0,12
30	2	0,58±0,17	0,53±0,30	0,51±0,21	0,46±0,22	0,46±0,22	0,20±0,14	0,60±0,07
30	3	0,49±0,23	0,53±0,30	0,46±0,22	0,37±0,26	0,39±0,25	0,32±0,21	0,66±0,11
30	4	0,42±0,25	0,53±0,29	0,42±0,24	0,31±0,26	0,34±0,25	0,39±0,22	0,70±0,13
30	5	0,37±0,25	0,47±0,28	0,36±0,23	0,26±0,20	0,30±0,21	0,46±0,22	0,75±0,12
30	6	0,41±0,25	0,43±0,27	0,34±0,23	0,27±0,19	0,27±0,23	0,49±0,21	0,78±0,12
30	7	0,45±0,29	0,42±0,26	0,33±0,24	0,30±0,22	0,27±0,23	0,51±0,22	0,80±0,12
30	8	0,48±0,32	0,42±0,22	<b>0,32±0,23</b>	0,30±0,22	0,28±0,22	0,51±0,23	<b>0,81±0,11</b>
30	9	0,54±0,34	0,42±0,22	0,36±0,24	0,34±0,25	0,32±0,25	0,49±0,24	<b>0,81±0,11</b>
40	2	0,62±0,16	0,54±0,31	0,55±0,19	0,51±0,21	0,52±0,21	0,13±0,10	0,56±0,05
40	3	0,55±0,19	0,53±0,31	0,49±0,21	0,43±0,23	0,44±0,23	0,23±0,16	0,61±0,08
40	4	0,48±0,21	0,53±0,28	0,45±0,19	0,36±0,23	0,37±0,22	0,32±0,21	0,66±0,11
40	5	0,44±0,25	0,53±0,29	0,43±0,23	0,33±0,25	0,34±0,25	0,38±0,22	0,69±0,13
40	6	0,39±0,26	0,48±0,31	0,38±0,24	0,29±0,24	0,30±0,24	0,42±0,23	0,73±0,13
40	7	0,38±0,26	0,43±0,30	0,34±0,24	0,28±0,23	0,28±0,23	0,46±0,23	0,76±0,13
40	8	0,40±0,29	0,45±0,29	0,34±0,24	0,29±0,25	0,28±0,24	0,48±0,24	0,78±0,14
40	9	0,44±0,30	0,44±0,26	0,34±0,25	0,30±0,24	0,29±0,26	0,49±0,25	0,79±0,14
50	2	0,64±0,14	0,55±0,32	0,58±0,18	0,55±0,19	0,55±0,19	0,09±0,08	0,54±0,04
50	3	0,59±0,16	0,54±0,31	0,53±0,19	0,48±0,21	0,48±0,21	0,16±0,12	0,58±0,06
50	4	0,54±0,19	0,53±0,29	0,48±0,21	0,42±0,22	0,42±0,22	0,24±0,16	0,62±0,09
50	5	0,50±0,23	0,54±0,29	0,47±0,22	0,38±0,26	0,40±0,25	0,31±0,21	0,66±0,11
50	6	0,44±0,25	0,53±0,29	0,45±0,22	0,34±0,25	0,36±0,24	0,36±0,23	0,69±0,13
50	7	0,39±0,24	0,48±0,31	0,37±0,22	0,27±0,23	0,31±0,22	0,41±0,23	0,72±0,13
50	8	0,38±0,25	0,47±0,30	0,36±0,24	0,28±0,23	0,30±0,23	0,44±0,23	0,74±0,13
50	9	0,39±0,27	0,48±0,28	0,36±0,25	0,28±0,23	0,30±0,25	0,46±0,24	0,76±0,13
60	2	0,65±0,15	0,58±0,32	0,60±0,18	0,57±0,19	0,57±0,20	0,07±0,06	0,53±0,04
60	3	0,61±0,16	0,54±0,33	0,55±0,19	0,50±0,21	0,51±0,21	0,13±0,10	0,56±0,05
60	4	0,56±0,18	0,53±0,30	0,50±0,21	0,45±0,22	0,45±0,22	0,20±0,13	0,60±0,07
60	5	0,53±0,22	0,55±0,29	0,49±0,22	0,42±0,25	0,43±0,24	0,26±0,17	0,63±0,09
60	6	0,49±0,24	0,55±0,28	0,46±0,22	0,37±0,25	0,38±0,25	0,33±0,21	0,66±0,11
60	7	0,42±0,24	0,51±0,29	0,40±0,22	0,30±0,25	0,33±0,23	0,38±0,22	0,69±0,12
60	8	0,40±0,24	0,49±0,30	0,38±0,23	0,28±0,25	0,32±0,23	0,42±0,22	0,72±0,13
60	9	0,37±0,24	0,47±0,28	0,36±0,23	0,27±0,22	0,29±0,21	0,45±0,22	0,74±0,13
70	2	0,66±0,13	0,63±0,30	0,61±0,16	0,59±0,16	0,59±0,17	0,05±0,05	0,52±0,03
70	3	0,64±0,15	0,54±0,34	0,59±0,18	0,55±0,20	0,55±0,20	0,09±0,08	0,54±0,05
70	4	0,61±0,16	0,53±0,32	0,54±0,20	0,50±0,21	0,49±0,22	0,15±0,11	0,57±0,06
70	5	0,58±0,18	0,56±0,30	0,51±0,22	0,46±0,23	0,46±0,23	0,20±0,15	0,60±0,08
70	6	0,53±0,20	0,54±0,29	0,48±0,22	0,41±0,24	0,42±0,24	0,26±0,19	0,63±0,10
70	7	0,49±0,22	0,53±0,31	0,45±0,21	0,37±0,25	0,39±0,23	0,30±0,20	0,65±0,11
70	8	0,45±0,24	0,53±0,29	0,44±0,22	0,34±0,25	0,37±0,23	0,34±0,21	0,67±0,12
70	9	0,41±0,25	0,51±0,30	0,41±0,22	0,31±0,24	0,34±0,23	0,38±0,22	0,69±0,12

**Tabela 43** – Análise dos Parâmetros da Técnica de BEMD, para a base Mini-MIAS.

$r_i$	$E_{\text{Área}}$	$E_{\text{FF}}$	$E_{\text{Per}}$	$E_{\text{FX}}$	$E_{\text{FY}}$	AOM	BAC
0,2	0,73±0,29	0,40±0,27	0,63±0,30	0,48±0,29	0,47±0,27	0,38±0,25	0,75±0,12
0,3	0,73±0,29	0,40±0,27	0,63±0,30	0,48±0,29	0,47±0,27	0,38±0,25	0,75±0,12
<b>0,4</b>	<b>0,73±0,29</b>	<b>0,40±0,27</b>	<b>0,63±0,30</b>	<b>0,48±0,29</b>	<b>0,47±0,27</b>	<b>0,38±0,25</b>	<b>0,75±0,12</b>
0,5	0,82±0,25	0,54±0,35	0,72±0,29	0,61±0,33	0,61±0,32	0,27±0,24	0,68±0,14
0,6	0,88±0,20	0,64±0,36	0,79±0,27	0,70±0,32	0,70±0,31	0,20±0,22	0,63±0,13
0,7	0,91±0,17	0,67±0,36	0,81±0,26	0,73±0,31	0,73±0,30	0,17±0,20	0,62±0,12
0,8	0,94±0,16	0,76±0,36	0,85±0,25	0,80±0,29	0,80±0,29	0,12±0,18	0,58±0,11
0,9	0,97±0,10	0,83±0,33	0,90±0,20	0,87±0,24	0,87±0,25	0,07±0,14	0,55±0,08

**Tabela 44** – Análise dos Parâmetros da Técnica MCW, para a base Mini-MIAS.

Tam.	Tipo	$E_{\text{Área}}$	$E_{\text{FF}}$	$E_{\text{Per}}$	$E_{\text{FX}}$	$E_{\text{FY}}$	AOM	BAC
3	<i>disk</i>	0,65±0,33	0,37±0,26	0,39±0,23	0,38±0,23	0,34±0,23	0,38±0,21	0,69±0,15
3	<i>square</i>	0,85±0,22	0,43±0,25	0,47±0,25	0,48±0,24	0,48±0,23	0,27±0,16	0,59±0,12
3	<i>diamond</i>	0,64±0,34	0,37±0,26	0,37±0,24	0,38±0,23	0,34±0,24	0,39±0,22	0,70±0,15
5	<i>disk</i>	0,56±0,37	0,36±0,26	0,38±0,24	0,34±0,23	0,34±0,23	0,41±0,25	0,69±0,16
5	<i>square</i>	0,65±0,33	0,37±0,26	0,39±0,23	0,38±0,23	0,34±0,23	0,38±0,21	0,69±0,15
5	<i>diamond</i>	0,57±0,37	0,36±0,25	0,39±0,24	0,35±0,23	0,36±0,23	0,40±0,25	0,69±0,17
7	<i>disk</i>	0,78±0,27	0,46±0,25	0,48±0,23	0,45±0,23	0,47±0,22	0,29±0,18	0,59±0,13
<b>7</b>	<b><i>square</i></b>	<b>0,48±0,36</b>	<b>0,33±0,24</b>	<b>0,35±0,24</b>	<b>0,31±0,22</b>	<b>0,30±0,21</b>	<b>0,43±0,24</b>	<b>0,71±0,16</b>
7	<i>diamond</i>	0,69±0,34	0,41±0,27	0,42±0,24	0,40±0,23	0,41±0,23	0,35±0,23	0,63±0,16
9	<i>disk</i>	0,85±0,22	0,46±0,27	0,50±0,24	0,49±0,23	0,51±0,21	0,26±0,16	0,56±0,11
9	<i>square</i>	0,62±0,37	0,40±0,27	0,39±0,23	0,37±0,22	0,37±0,24	0,39±0,24	0,67±0,16
9	<i>diamond</i>	0,81±0,26	0,46±0,26	0,48±0,24	0,46±0,22	0,48±0,22	0,28±0,17	0,58±0,13
11	<i>disk</i>	0,83±0,26	0,48±0,27	0,47±0,25	0,47±0,25	0,49±0,23	0,26±0,16	0,55±0,10
11	<i>square</i>	0,75±0,30	0,44±0,26	0,44±0,22	0,42±0,23	0,43±0,23	0,32±0,20	0,61±0,14
11	<i>diamond</i>	0,84±0,24	0,46±0,28	0,48±0,25	0,48±0,25	0,49±0,22	0,27±0,17	0,57±0,11

**Tabela 45** – Análise dos Parâmetros da Técnica de Segmentação por Abordagem Topográfica, para a base IRMA, utilizando métricas relacionadas à forma.

NL	Prof.	$E_{\text{Área}}$	$E_{\text{FF}}$	$E_{\text{Per}}$	$E_{\text{FX}}$	$E_{\text{FY}}$	AOM	BAC
10	2	0,66±0,36	0,33±0,25	0,53±0,35	0,45±0,36	0,46±0,36	0,36±0,28	0,69±0,13
10	3	0,78±0,29	0,33±0,29	0,56±0,34	0,48±0,36	0,49±0,36	0,31±0,24	0,59±0,11
10	4	0,82±0,26	0,33±0,30	0,56±0,35	0,49±0,37	0,50±0,35	0,29±0,23	0,56±0,09
10	5	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
10	6	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
10	7	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
10	8	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
10	9	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
20	2	0,53±0,30	0,43±0,33	0,48±0,31	0,43±0,33	0,43±0,32	0,37±0,25	0,71±0,15
20	3	0,57±0,36	0,36±0,25	0,51±0,34	0,44±0,34	0,43±0,34	0,39±0,26	0,73±0,13
20	4	0,66±0,36	0,33±0,25	0,53±0,35	0,45±0,36	0,46±0,36	0,36±0,28	0,69±0,13
20	5	0,72±0,34	0,32±0,28	0,54±0,35	0,46±0,37	0,48±0,36	0,33±0,27	0,63±0,13
20	6	0,77±0,30	0,33±0,29	0,56±0,34	0,48±0,36	0,49±0,36	0,31±0,25	0,59±0,11
20	7	0,80±0,27	0,33±0,30	0,56±0,34	0,49±0,36	0,50±0,35	0,29±0,24	0,57±0,10
20	8	0,81±0,26	0,33±0,30	0,56±0,35	0,49±0,36	0,50±0,36	0,29±0,23	0,56±0,09
20	9	0,82±0,25	0,33±0,30	0,56±0,35	0,49±0,37	0,50±0,36	0,28±0,23	0,55±0,08
30	2	0,54±0,26	0,45±0,36	<b>0,48±0,29</b>	0,44±0,30	0,45±0,30	0,30±0,23	0,65±0,13
30	3	0,53±0,30	0,43±0,32	0,49±0,31	0,43±0,33	0,43±0,32	0,36±0,25	0,71±0,15
30	4	0,55±0,35	0,37±0,27	0,50±0,34	0,43±0,34	0,43±0,33	0,39±0,26	0,73±0,14
30	5	0,61±0,35	0,33±0,25	0,53±0,33	0,44±0,35	0,45±0,35	0,38±0,27	0,72±0,13
30	6	0,66±0,36	0,33±0,26	0,54±0,35	0,45±0,36	0,46±0,36	0,36±0,27	0,68±0,13
30	7	0,70±0,35	0,33±0,27	0,54±0,35	0,46±0,37	0,47±0,36	0,34±0,27	0,65±0,13
30	8	0,74±0,33	0,33±0,28	0,55±0,34	0,47±0,36	0,48±0,36	0,32±0,26	0,62±0,13
30	9	0,77±0,30	0,33±0,29	0,55±0,34	0,48±0,36	0,49±0,36	0,31±0,25	0,59±0,11
40	2	0,60±0,22	0,47±0,37	0,52±0,26	0,49±0,27	0,50±0,27	0,23±0,19	0,61±0,10
40	3	0,54±0,28	0,46±0,36	0,49±0,30	0,45±0,32	0,45±0,31	0,32±0,24	0,66±0,14
40	4	0,53±0,30	0,43±0,32	0,49±0,31	0,43±0,33	0,42±0,31	0,37±0,25	0,71±0,15
40	5	0,54±0,34	0,38±0,28	0,49±0,34	0,43±0,34	0,43±0,33	0,38±0,26	0,73±0,14
40	6	0,58±0,35	0,36±0,25	0,52±0,34	0,44±0,35	0,44±0,34	0,38±0,27	0,73±0,13
40	7	0,61±0,36	<b>0,32±0,24</b>	0,52±0,34	0,43±0,35	0,45±0,35	0,38±0,27	0,71±0,13
40	8	0,66±0,36	0,33±0,25	0,54±0,35	0,45±0,36	0,47±0,36	0,36±0,28	0,68±0,13
40	9	0,69±0,35	0,33±0,27	0,54±0,35	0,46±0,36	0,47±0,36	0,35±0,27	0,66±0,14
50	2	0,62±0,20	0,48±0,36	0,55±0,24	0,52±0,25	0,52±0,25	0,17±0,16	0,59±0,09
50	3	0,57±0,24	0,46±0,36	0,50±0,28	0,47±0,29	0,48±0,28	0,26±0,21	0,63±0,12
50	4	0,54±0,28	0,45±0,36	0,49±0,30	0,45±0,32	0,45±0,32	0,32±0,25	0,67±0,14
50	5	0,54±0,29	0,42±0,32	0,49±0,31	0,43±0,32	0,43±0,31	0,36±0,24	0,71±0,15
50	6	0,54±0,33	0,38±0,29	0,49±0,33	0,42±0,34	0,43±0,33	0,38±0,25	0,73±0,14
50	7	0,56±0,35	0,37±0,26	0,51±0,33	0,44±0,34	0,43±0,34	0,38±0,26	0,73±0,14
50	8	0,59±0,36	0,35±0,25	0,52±0,34	0,44±0,35	0,44±0,35	0,38±0,27	0,73±0,13
50	9	0,62±0,37	0,33±0,24	0,53±0,34	0,44±0,36	0,45±0,35	0,38±0,27	0,71±0,13
60	2	0,64±0,19	0,49±0,36	0,57±0,23	0,55±0,24	0,55±0,24	0,14±0,14	0,57±0,07
60	3	0,60±0,22	0,47±0,37	0,53±0,26	0,50±0,27	0,50±0,27	0,22±0,19	0,61±0,10
60	4	0,55±0,26	0,46±0,37	0,49±0,29	0,45±0,31	0,46±0,30	0,29±0,23	0,65±0,13
60	5	<b>0,52±0,29</b>	0,44±0,34	0,48±0,30	0,43±0,32	0,43±0,31	0,34±0,25	0,68±0,15
60	6	0,52±0,31	0,42±0,32	0,48±0,32	<b>0,42±0,34</b>	<b>0,42±0,33</b>	0,37±0,26	0,71±0,15
60	7	0,53±0,32	0,40±0,29	0,49±0,33	<b>0,42±0,34</b>	<b>0,42±0,33</b>	0,38±0,26	0,73±0,14
<b>60</b>	<b>8</b>	0,54±0,35	0,37±0,26	0,50±0,34	<b>0,42±0,33</b>	<b>0,42±0,34</b>	<b>0,39±0,27</b>	<b>0,74±0,14</b>
60	9	0,57±0,35	0,36±0,25	0,51±0,33	0,43±0,34	0,43±0,34	<b>0,39±0,26</b>	0,73±0,13
70	2	0,65±0,18	0,50±0,36	0,59±0,22	0,57±0,23	0,57±0,23	0,12±0,13	0,56±0,06
70	3	0,62±0,20	0,48±0,36	0,54±0,25	0,51±0,26	0,52±0,26	0,19±0,17	0,60±0,09
70	4	0,57±0,24	0,46±0,36	0,50±0,27	0,47±0,29	0,48±0,28	0,26±0,21	0,63±0,12
70	5	0,54±0,27	0,44±0,36	0,48±0,29	0,44±0,31	0,45±0,30	0,31±0,23	0,66±0,13
70	6	0,53±0,29	0,45±0,35	0,48±0,30	0,44±0,32	0,44±0,32	0,34±0,25	0,68±0,15
70	7	0,53±0,30	0,42±0,31	0,48±0,31	0,42±0,32	0,43±0,31	0,37±0,24	0,71±0,14
70	8	0,53±0,33	0,39±0,30	0,49±0,33	0,42±0,34	0,42±0,32	0,38±0,25	0,72±0,15
70	9	0,55±0,34	0,38±0,28	0,50±0,33	0,43±0,34	0,43±0,33	<b>0,39±0,26</b>	0,73±0,14

**Tabela 46** – Análise dos Parâmetros da Técnica de BEMD, para a base IRMA, utilizando as métricas relacionadas à forma.

$r_i$	$E_{\text{Área}}$	$E_{\text{FF}}$	$E_{\text{Per}}$	$E_{\text{FX}}$	$E_{\text{FY}}$	AOM	BAC
0,2	0,74±0,34	0,38±0,23	0,67±0,34	0,51±0,38	0,53±0,37	0,32±0,27	0,64±0,13
0,3	0,74±0,34	0,38±0,23	0,67±0,34	0,51±0,38	0,53±0,37	0,32±0,27	0,64±0,13
<b>0,4</b>	<b>0,74±0,34</b>	<b>0,38±0,23</b>	<b>0,67±0,34</b>	<b>0,51±0,38</b>	<b>0,53±0,37</b>	<b>0,32±0,27</b>	<b>0,64±0,13</b>
0,5	0,77±0,33	0,42±0,26	0,70±0,34	0,55±0,38	0,57±0,37	0,29±0,27	0,63±0,13
0,6	0,79±0,32	0,44±0,28	0,72±0,33	0,58±0,39	0,59±0,37	0,27±0,27	0,61±0,13
0,7	0,82±0,30	0,47±0,31	0,74±0,33	0,62±0,38	0,63±0,37	0,24±0,26	0,60±0,12
0,8	0,86±0,27	0,53±0,34	0,78±0,31	0,68±0,37	0,69±0,36	0,19±0,25	0,58±0,11
0,9	0,91±0,23	0,61±0,36	0,84±0,28	0,76±0,34	0,77±0,33	0,14±0,22	0,55±0,10

**Tabela 47** – Análise dos Parâmetros da Técnica MCW, para a base IRMA, utilizando as métricas relacionadas à forma.

Tam.	Tipo	$E_{\text{Área}}$	$E_{\text{FF}}$	$E_{\text{Per}}$	$E_{\text{FX}}$	$E_{\text{FY}}$	AOM	BAC
3	<i>disk</i>	0,61±0,33	0,40±0,30	0,49±0,35	0,44±0,36	0,44±0,36	0,31±0,27	0,59±0,16
3	<i>square</i>	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
3	<i>diamond</i>	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
<b>5</b>	<b>disk</b>	<b>0,57±0,34</b>	0,43±0,33	<b>0,45±0,35</b>	<b>0,41±0,37</b>	<b>0,40±0,36</b>	<b>0,33±0,28</b>	<b>0,59±0,17</b>
5	<i>square</i>	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
5	<i>diamond</i>	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
7	<i>disk</i>	0,67±0,32	0,41±0,31	0,47±0,36	0,42±0,37	0,42±0,35	0,33±0,26	0,56±0,17
7	<i>square</i>	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
7	<i>diamond</i>	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
9	<i>disk</i>	0,74±0,30	0,39±0,32	0,53±0,36	0,47±0,37	0,47±0,36	0,29±0,25	0,53±0,14
9	<i>square</i>	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
9	<i>diamond</i>	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
11	<i>disk</i>	0,80±0,26	<b>0,37±0,31</b>	0,56±0,35	0,49±0,37	0,50±0,36	0,27±0,23	0,52±0,12
11	<i>square</i>	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00
11	<i>diamond</i>	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	1,00±0,00	0,00±0,00	0,50±0,00

**Tabela 48** – Análise dos Parâmetros para do algoritmo proposto, para a base IRMA, utilizando-se a métricas relacionadas à forma.

NS	$\alpha$	$E_{\text{Área}}$	$E_{\text{FF}}$	$E_{\text{Per}}$	$E_{\text{FX}}$	$E_{\text{FY}}$	AOM	BAC
5	1	0,68±0,17	0,50±0,33	0,62±0,22	0,62±0,21	0,61±0,23	0,06±0,12	0,53±0,06
5	2	0,66±0,19	0,48±0,33	0,59±0,25	0,58±0,24	0,59±0,25	0,09±0,16	0,55±0,09
5	4	0,64±0,22	0,47±0,32	0,54±0,28	0,55±0,27	0,55±0,27	0,15±0,20	0,57±0,11
5	6	0,62±0,23	0,46±0,32	0,52±0,29	0,52±0,29	0,52±0,28	0,18±0,22	0,59±0,12
5	8	0,60±0,24	0,46±0,32	0,49±0,30	0,49±0,29	0,50±0,29	0,21±0,24	0,61±0,13
5	10	0,59±0,26	0,47±0,31	0,48±0,31	0,48±0,29	0,49±0,29	0,23±0,24	0,62±0,14
5	12	0,59±0,26	0,46±0,31	0,48±0,31	0,48±0,30	0,48±0,30	0,25±0,24	0,62±0,14
5	14	0,59±0,27	0,46±0,31	0,47±0,32	0,47±0,31	0,47±0,30	0,26±0,24	0,63±0,14
10	1	0,66±0,17	0,46±0,32	0,58±0,23	0,58±0,23	0,59±0,23	0,09±0,12	0,54±0,07
10	2	0,63±0,20	0,46±0,32	0,52±0,28	0,53±0,27	0,54±0,26	0,15±0,18	0,58±0,10
10	4	0,58±0,25	0,46±0,31	0,46±0,31	0,47±0,30	0,47±0,29	0,24±0,24	0,62±0,13
10	6	0,55±0,27	0,44±0,31	0,44±0,32	0,44±0,31	0,44±0,31	0,29±0,25	0,64±0,14
10	8	0,52±0,28	0,42±0,31	0,43±0,32	0,41±0,31	0,42±0,31	0,33±0,26	0,66±0,15
10	10	0,51±0,29	0,42±0,30	0,43±0,31	0,40±0,31	0,40±0,31	0,35±0,26	0,68±0,16
10	12	0,51±0,30	0,41±0,29	0,43±0,31	0,40±0,31	0,39±0,31	0,37±0,26	0,69±0,16
10	14	0,51±0,32	0,41±0,30	0,44±0,32	0,40±0,31	0,39±0,32	0,37±0,27	0,69±0,17
15	1	0,61±0,20	0,44±0,31	0,48±0,28	0,50±0,26	0,50±0,26	0,18±0,19	0,59±0,10
15	2	0,54±0,24	0,42±0,30	0,41±0,30	0,43±0,29	0,43±0,28	0,28±0,24	0,64±0,13
15	4	0,48±0,28	0,42±0,30	0,39±0,31	0,38±0,30	0,37±0,30	0,38±0,26	0,69±0,15
15	6	0,45±0,31	0,42±0,29	0,41±0,32	0,38±0,31	0,36±0,31	0,42±0,26	0,72±0,16
15	8	0,50±0,33	0,40±0,27	0,47±0,31	0,40±0,32	0,38±0,32	0,40±0,26	0,71±0,17
15	10	0,58±0,35	0,38±0,28	0,51±0,33	0,43±0,33	0,41±0,33	0,37±0,25	0,69±0,17
15	12	0,66±0,35	0,39±0,29	0,54±0,34	0,46±0,35	0,45±0,35	0,33±0,25	0,65±0,16
15	14	0,73±0,32	0,38±0,31	0,57±0,34	0,48±0,36	0,49±0,35	0,29±0,24	0,60±0,14
20	1	0,55±0,22	0,42±0,29	0,41±0,29	0,43±0,28	0,44±0,27	0,27±0,22	0,63±0,12
20	2	0,48±0,26	0,40±0,29	0,38±0,30	0,38±0,29	0,37±0,29	0,37±0,25	0,69±0,15
20	4	0,44±0,30	0,40±0,26	0,41±0,30	0,35±0,29	0,33±0,29	0,44±0,26	0,74±0,16
20	6	0,54±0,35	0,38±0,26	0,49±0,33	0,41±0,33	0,39±0,32	0,40±0,25	0,71±0,17
20	8	0,70±0,33	0,37±0,28	0,55±0,34	0,46±0,34	0,46±0,35	0,32±0,24	0,63±0,15
20	10	0,76±0,31	0,35±0,30	0,57±0,35	0,48±0,36	0,49±0,35	0,29±0,24	0,58±0,13
20	12	0,79±0,28	0,35±0,32	0,57±0,35	0,49±0,36	0,50±0,36	0,28±0,23	0,55±0,11
20	14	0,81±0,26	0,35±0,32	0,57±0,35	0,50±0,36	0,51±0,36	0,28±0,23	0,54±0,10
25	1	0,50±0,23	0,38±0,27	0,37±0,28	0,40±0,26	0,39±0,26	0,32±0,24	0,66±0,13
25	2	0,45±0,27	0,38±0,26	0,37±0,29	0,35±0,27	0,34±0,27	0,42±0,25	0,72±0,15
25	4	0,48±0,34	0,36±0,22	0,46±0,32	0,38±0,31	0,36±0,30	0,43±0,25	0,75±0,16
25	6	0,70±0,33	0,34±0,26	0,55±0,34	0,46±0,35	0,46±0,34	0,33±0,24	0,65±0,15
25	8	0,79±0,29	0,32±0,29	0,57±0,34	0,49±0,36	0,50±0,35	0,29±0,24	0,56±0,12
25	10	0,82±0,25	0,33±0,30	0,57±0,34	0,49±0,36	0,51±0,36	0,27±0,23	0,54±0,09
25	12	0,83±0,24	0,33±0,30	0,57±0,35	0,50±0,36	0,51±0,36	0,27±0,22	0,53±0,06
25	14	0,84±0,23	0,33±0,30	0,57±0,35	0,50±0,36	0,51±0,36	0,27±0,22	0,52±0,05
30	1	0,47±0,23	0,37±0,25	0,35±0,27	0,37±0,25	0,37±0,25	0,35±0,24	0,68±0,14
30	2	<b>0,42±0,27</b>	0,37±0,24	0,37±0,28	0,33±0,26	0,31±0,25	0,45±0,24	0,74±0,16
30	4	0,57±0,37	0,34±0,21	0,51±0,34	0,42±0,33	0,41±0,33	0,39±0,25	0,73±0,15
30	6	0,77±0,30	0,33±0,28	0,56±0,35	0,48±0,35	0,49±0,35	0,30±0,24	0,58±0,12
30	8	0,82±0,25	0,33±0,30	0,57±0,34	0,49±0,36	0,51±0,35	0,28±0,23	0,54±0,09
30	10	0,84±0,23	0,33±0,30	0,57±0,35	0,50±0,36	0,51±0,36	0,27±0,22	0,53±0,05
30	12	0,84±0,22	0,33±0,30	0,57±0,35	0,50±0,36	0,51±0,36	0,27±0,22	0,52±0,04
30	14	0,85±0,22	0,33±0,30	0,57±0,35	0,50±0,36	0,51±0,36	0,27±0,22	0,52±0,03
35	1	0,44±0,23	0,36±0,23	<b>0,33±0,25</b>	0,35±0,24	0,33±0,24	0,39±0,23	0,71±0,14
35	2	0,42±0,28	0,35±0,22	0,39±0,28	0,33±0,26	0,30±0,25	<b>0,47±0,23</b>	0,77±0,14
35	4	0,67±0,35	0,34±0,24	0,55±0,34	0,45±0,35	0,45±0,35	0,35±0,25	0,67±0,15
35	6	0,81±0,26	0,33±0,30	0,57±0,35	0,49±0,36	0,50±0,36	0,28±0,23	0,55±0,09
35	8	0,84±0,24	0,32±0,30	0,57±0,35	0,50±0,36	0,51±0,36	0,27±0,22	0,53±0,06
35	10	0,84±0,23	0,32±0,30	0,57±0,35	0,50±0,36	0,51±0,36	0,27±0,22	0,52±0,04
35	12	0,85±0,22	0,33±0,30	0,58±0,35	0,50±0,36	0,51±0,36	0,27±0,22	0,52±0,02
35	14	0,85±0,22	0,33±0,30	0,58±0,35	0,50±0,36	0,51±0,36	0,27±0,22	0,52±0,01
40	1	0,43±0,24	0,36±0,23	0,33±0,25	0,35±0,24	0,33±0,24	0,40±0,24	0,72±0,14
40	2	0,43±0,29	0,34±0,20	0,40±0,29	<b>0,33±0,26</b>	<b>0,30±0,25</b>	<b>0,47±0,23</b>	<b>0,78±0,14</b>
40	4	0,72±0,33	<b>0,32±0,25</b>	0,56±0,34	0,46±0,36	0,48±0,35	0,32±0,24	0,63±0,13
40	6	0,83±0,25	0,32±0,30	0,57±0,34	0,50±0,36	0,51±0,36	0,27±0,23	0,54±0,07
40	8	0,84±0,23	0,32±0,30	0,57±0,35	0,50±0,36	0,51±0,36	0,27±0,22	0,53±0,04
40	10	0,85±0,22	0,32±0,30	0,57±0,35	0,50±0,36	0,51±0,36	0,27±0,22	0,52±0,03
40	12	0,85±0,22	0,32±0,30	0,58±0,35	0,50±0,36	0,51±0,36	0,27±0,22	0,52±0,02
40	14	0,85±0,22	0,33±0,30	0,58±0,35	0,50±0,36	0,51±0,36	0,27±0,22	0,52±0,01

**Tabela 49** – Análise dos Parâmetros da Técnica de Segmentação por Abordagem Topográfica, para a base IRMA, utilizando-se a métrica de precisão.

Configuração		Tipo 1		Tipo 2	
NL	Prof	circ + spic	circ + spic + indef	circ+spic	circ+spic+indef
10	2	79,42±4,49	78,67±4,60	78,86±4,71	<b>80,77±4,35</b>
10	3	76,83±4,96	74,29±3,63	74,93±2,59	72,19±3,48
10	4	70,18±3,46	72,61±3,24	69,32±3,84	68,28±2,24
10	5	53,25±0,17	52,15±0,15	53,99±0,13	55,00±0,00
10	6	53,27±0,12	52,15±0,15	53,99±0,13	55,00±0,00
10	7	53,16±0,72	52,12±0,28	54,03±0,00	55,00±0,00
10	8	53,25±0,17	52,18±0,00	54,03±0,00	54,94±0,32
10	9	53,25±0,17	52,15±0,15	54,01±0,10	54,96±0,21
20	2	81,12±4,74	76,35±4,84	78,70±5,33	75,76±4,64
20	3	<b>85,17±4,16</b>	81,06±5,27	79,88±7,40	77,56±7,27
20	4	81,15±4,60	77,67±4,79	79,33±6,74	74,40±6,00
20	5	77,48±4,94	73,72±5,37	77,09±4,51	74,85±4,05
20	6	78,59±4,00	75,27±3,21	71,90±3,68	71,58±3,77
20	7	69,60±3,93	72,49±2,38	71,05±2,83	68,60±2,04
20	8	72,11±2,21	74,85±1,89	69,11±2,58	66,71±1,66
20	9	73,00±2,31	74,23±2,03	67,29±1,86	66,20±1,75
30	2	77,51±5,05	76,57±3,73	79,57±3,77	76,75±5,22
30	3	80,31±4,44	74,58±3,90	80,49±4,56	76,92±4,74
30	4	83,71±4,23	80,41±4,15	80,96±5,95	75,99±5,77
30	5	82,11±5,22	78,78±5,02	78,16±6,95	75,74±8,55
30	6	78,52±4,07	79,63±4,27	78,41±5,79	79,10±5,42
30	7	82,06±5,52	76,05±4,15	82,87±4,94	75,92±5,50
30	8	78,61±3,73	76,53±3,71	75,62±3,90	73,95±3,77
30	9	75,36±3,82	74,19±3,90	74,85±4,11	71,76±3,23
40	2	76,43±4,02	73,14±3,46	76,02±4,41	77,34±3,51
40	3	74,33±4,56	73,40±3,69	80,81±5,19	78,98±4,18
40	4	81,79±4,20	75,69±3,31	81,50±5,38	75,97±5,23
40	5	84,09±4,06	79,90±5,06	81,54±6,80	78,58±5,95
40	6	80,11±4,65	77,55±5,53	80,50±8,28	76,55±7,11
40	7	78,15±5,11	77,21±4,29	78,76±5,24	73,99±6,07
40	8	80,73±4,82	76,27±4,61	81,67±5,24	79,35±5,22
40	9	78,88±6,07	77,84±6,07	76,86±5,32	75,31±5,79
50	2	72,68±4,17	69,45±3,07	72,48±5,07	69,46±3,79
50	3	74,94±3,92	73,91±3,67	76,40±5,16	75,53±3,62
50	4	79,23±4,25	75,36±4,09	78,66±4,39	75,60±5,55
50	5	79,78±4,35	73,71±5,19	80,52±5,50	76,41±4,69
50	6	82,70±4,33	77,80±4,51	82,15±5,65	77,01±6,19
50	7	84,03±4,77	<b>82,85±4,24</b>	80,58±6,94	74,31±7,66
50	8	81,86±4,63	79,06±3,90	80,94±6,99	79,72±6,16
50	9	78,98±5,00	77,89±4,63	79,60±6,73	74,37±7,93
60	2	71,08±3,32	67,36±2,78	74,31±4,14	71,27±3,94
60	3	74,41±4,75	73,44±3,75	78,78±3,92	73,89±4,07
60	4	79,78±3,46	72,61±4,28	82,48±4,33	77,21±4,02
60	5	80,93±3,85	75,56±3,38	<b>84,05±3,78</b>	79,85±4,29
60	6	80,84±7,07	76,36±4,01	80,23±5,24	76,31±5,83
60	7	81,93±4,76	75,98±4,97	83,43±5,36	77,56±5,55
60	8	80,84±4,28	78,09±5,32	80,59±7,08	77,63±6,09
60	9	79,55±6,30	79,00±4,49	80,10±6,70	75,76±6,92
70	2	71,53±3,31	67,85±2,62	72,84±5,29	68,33±3,77
70	3	73,85±4,48	69,98±3,46	76,35±4,14	72,86±3,50
70	4	76,20±6,06	75,03±4,08	76,27±4,96	76,30±3,60
70	5	76,80±4,91	75,84±3,90	79,19±3,44	79,05±4,89
70	6	79,78±5,47	76,82±3,82	77,84±5,01	78,79±4,69
70	7	78,74±6,04	73,49±4,39	81,16±4,96	75,47±5,04
70	8	77,88±5,08	74,94±5,59	82,37±5,84	78,21±5,35
70	9	82,04±5,20	77,97±5,24	78,73±5,76	76,52±6,73

**Tabela 50** – Análise dos Parâmetros da Técnica de Segmentação por BEMD, para a base IRMA, utilizando-se a métrica de precisão.

Conf.	Tipo 1		Tipo 2	
$r_i$	circ+spic	circ+spic+indef.	circ+spic	circ+spic+indef.
0,2	<b>78,95±4,04</b>	<b>76,25±3,67</b>	<b>79,28±4,74</b>	<b>76,63±3,79</b>
0,3	77,78±3,66	75,72±2,93	79,23±3,12	76,63±4,57
0,4	78,37±3,36	76,17±3,74	79,52±4,54	75,78±4,49
0,5	75,73±4,07	73,15±3,42	79,04±4,40	74,59±4,08
0,6	75,41±3,93	73,25±2,79	77,54±3,57	73,25±3,83
0,7	75,13±4,64	72,95±3,55	73,08±4,10	71,81±3,11
0,8	72,51±5,27	69,55±2,88	72,61±3,36	71,06±3,43
0,9	70,09±4,55	69,30±2,91	69,85±3,50	70,36±2,06

**Tabela 51** – Análise dos Parâmetros da Técnica de Segmentação por MCW, para a base IRMA utilizando-se a métrica de precisão.

Conf.		Tipo1		Tipo2	
Tam.	Tipo	circ_spic	circ+spic+indef.	circ_spic	circ+spic+indef.
3	<i>diamond</i>	74,22±4,72	<b>72,18±3,93</b>	<b>76,61±4,47</b>	<b>73,89±3,61</b>
3	<i>disk</i>	69,11±5,75	70,63±5,33	72,22±3,84	73,26±3,85
3	<i>square</i>	62,58±4,27	65,79±2,50	66,53±2,34	64,40±2,67
5	<i>diamond</i>	73,97±4,04	70,19±4,19	71,59±5,25	73,65±4,10
5	<i>disk</i>	69,66±4,59	69,20±4,16	73,97±3,10	70,09±3,67
5	<i>square</i>	71,21±5,55	70,08±4,59	71,61±4,83	73,34±4,55
7	<i>diamond</i>	63,05±4,58	61,67±3,15	65,55±4,18	61,43±4,50
7	<i>disk</i>	62,12±2,45	58,32±2,68	61,94±3,92	61,45±3,33
7	<i>square</i>	<b>74,41±4,49</b>	70,84±3,69	74,00±4,51	73,57±3,68
9	<i>diamond</i>	58,72±2,62	57,35±2,72	58,70±2,33	59,21±2,26
9	<i>disk</i>	56,78±3,05	56,75±1,95	56,40±2,71	56,07±2,86
9	<i>square</i>	71,45±4,16	68,97±3,02	72,48±4,38	68,74±3,65
11	<i>diamond</i>	58,83±1,93	57,50±1,56	52,88±2,04	51,75±2,31
11	<i>disk</i>	55,97±1,49	55,81±1,45	52,94±2,09	50,88±1,95
11	<i>square</i>	63,16±4,60	61,29±3,28	65,89±3,37	61,01±4,13

**Tabela 52** – Análise dos Parâmetros para do algoritmo proposto, para tecido tipo 1 da base IRMA, utilizando-se a métrica de precisão.

Config.		DE	
NS	$\alpha$	circ+spic	circ+spic+indef.
5	1	73,38±4,23	66,33±2,91
5	2	76,75±3,05	68,88±2,82
5	4	76,62±4,26	72,74±3,74
5	6	73,80±5,00	72,82±4,69
5	8	75,43±4,58	71,05±3,90
5	10	75,81±5,28	70,89±3,34
5	12	76,59±4,90	71,54±3,45
5	14	78,30±4,01	72,95±4,60
10	1	68,26±4,60	65,22±3,25
10	2	78,46±4,77	67,96±3,81
10	4	74,99±4,09	69,65±4,19
10	6	76,23±5,56	71,72±4,16
10	8	79,87±4,04	70,52±5,57
10	10	75,77±4,47	73,17±3,53
10	12	75,64±4,48	73,68±3,75
10	14	77,94±5,38	75,45±4,45
15	1	77,28±4,58	69,68±3,82
15	2	78,49±4,99	70,97±4,05
15	4	77,15±4,20	74,84±4,25
15	6	79,68±5,61	73,96±3,63
15	8	82,70±4,48	77,21±5,22
15	10	79,77±6,18	76,64±4,30
15	12	81,43±3,96	78,29±3,32
15	14	83,83±4,09	75,94±5,46
20	1	75,88±4,54	68,67±4,11
20	2	79,29±5,22	72,49±3,38
20	4	84,12±4,92	76,12±3,96
20	6	80,67±5,93	79,33±4,64
20	8	81,57±5,56	76,63±5,65
20	10	76,31±6,11	73,37±7,06
20	12	71,96±3,24	71,24±4,99
20	14	64,07±2,63	63,46±3,84
25	1	77,95±4,65	72,53±4,58
25	2	79,03±5,23	77,41±4,57
25	4	80,06±5,21	77,66±3,51
25	6	86,34±5,22	<b>80,00±4,92</b>
25	8	72,51±4,30	74,49±4,63
25	10	64,66±2,32	64,76±3,28
25	12	57,89±1,43	59,42±2,41
25	14	54,05±1,19	55,84±1,17
30	1	77,53±5,67	74,82±4,54
30	2	81,46±6,13	76,80±5,04
30	4	80,61±6,62	77,30±5,31
30	6	77,58±5,07	76,08±6,75
30	8	61,24±1,23	60,01±3,14
30	10	54,07±1,36	56,43±1,53
30	12	52,24±0,94	55,93±0,67
30	14	51,24±0,51	52,93±0,75
35	1	82,63±4,59	74,25±3,72
35	2	76,29±4,53	75,98±5,25
35	4	80,95±6,17	77,14±7,97
35	6	67,90±2,89	68,23±3,98
35	8	52,89±1,10	55,40±1,60
35	10	49,34±0,71	51,62±0,53
35	12	49,10±0,59	50,88±0,41
35	14	47,74±0,71	48,64±0,68
40	1	78,24±6,89	73,44±4,53
40	2	83,76±4,23	79,34±3,63
40	4	<b>86,75±3,38</b>	75,18±7,97
40	6	59,84±1,85	62,62±3,27
40	8	52,11±0,78	55,11±0,86
40	10	47,93±0,82	51,10±0,58
40	12	47,11±0,58	49,21±0,53
40	14	47,14±0,52	49,79±0,58

**Tabela 53** – Análise dos Parâmetros para do algoritmo proposto, para tecido tipo 2 da base IRMA, utilizando-se a métrica de precisão.

Config.		DE	
NS	$\alpha$	circ+spic	circ+spic+indef.
5	1	71,83±3,85	68,85±1,88
5	2	70,42±3,47	69,01±2,31
5	4	70,98±3,99	68,84±3,22
5	6	71,94±3,85	68,69±3,45
5	8	71,37±3,76	68,13±3,78
5	10	71,50±3,27	70,83±4,41
5	12	71,52±4,20	71,16±4,97
5	14	78,21±3,78	73,24±3,73
10	1	72,75±4,54	64,38±2,38
10	2	73,75±4,74	67,46±3,03
10	4	79,54±4,46	69,34±3,17
10	6	77,19±3,53	69,30±3,28
10	8	77,09±4,26	76,11±4,68
10	10	77,58±4,23	75,44±3,89
10	12	79,95±6,12	75,72±4,28
10	14	75,47±5,17	74,85±4,60
15	1	74,31±5,45	68,49±2,61
15	2	81,94±4,40	73,81±3,97
15	4	81,79±5,38	73,01±5,78
15	6	82,11±5,10	75,88±5,28
15	8	79,34±5,30	76,98±4,14
15	10	78,70±4,28	75,63±6,55
15	12	73,18±4,25	75,29±5,65
15	14	66,04±3,14	77,48±4,55
20	1	76,67±5,76	71,33±4,26
20	2	81,07±4,57	78,59±4,51
20	4	81,34±4,75	77,83±5,15
20	6	76,31±8,01	75,84±5,62
20	8	73,20±4,09	78,17±7,64
20	10	63,25±1,34	73,84±7,04
20	12	54,72±1,16	69,43±4,72
20	14	52,60±0,96	65,31±3,24
25	1	79,75±4,71	73,56±4,35
25	2	<b>84,84±3,66</b>	77,69±6,18
25	4	83,38±5,25	77,54±5,68
25	6	72,28±3,60	<b>81,52±5,47</b>
25	8	58,64±1,60	72,78±5,16
25	10	51,62±0,97	62,63±2,43
25	12	49,59±0,64	57,84±1,13
25	14	46,98±0,82	53,23±1,27
30	1	79,51±6,27	74,60±5,71
30	2	79,85±5,86	81,32±4,84
30	4	81,30±4,58	78,17±6,93
30	6	59,96±2,07	78,79±3,25
30	8	50,70±0,84	61,17±2,16
30	10	48,74±0,84	52,58±1,20
30	12	46,94±0,61	48,37±0,94
30	14	47,07±0,38	46,25±0,55
35	1	77,53±4,88	74,52±4,31
35	2	82,78±5,53	78,99±4,78
35	4	75,29±3,68	80,64±6,73
35	6	53,28±1,13	68,02±3,79
35	8	48,04±0,53	50,72±1,04
35	10	46,66±0,43	46,87±0,49
35	12	46,37±0,38	45,88±0,27
35	14	46,23±0,34	45,62±0,28
40	1	78,53±3,26	75,03±5,29
40	2	81,19±7,12	80,01±5,61
40	4	71,21±2,78	77,77±8,87
40	6	49,76±0,69	59,34±1,88
40	8	46,41±0,51	48,26±0,50
40	10	46,67±0,43	45,30±0,27
40	12	46,57±0,46	45,96±2,43
40	14	46,74±0,38	45,33±0,17

**APÊNDICE B – Base de Dados****Tabela 54** – Lista de imagens de lesão to tipo circunscrito e espiculado descartadas na análise de segmentação da base IRMA

Num.	Nome
1	1002946
2	1002988
3	1003017
4	1003395
5	1003741
6	1003759
7	1003769
8	1003895
9	1003985
10	1004031
11	1004053
12	1004076
13	1004238
14	1004286
15	1004571
16	1004597
17	1004622
18	1004637
19	1004852
20	1004866
21	1005020
22	1005050
23	1005167
24	1005249
25	1005252
26	1005352
27	1005397
28	1005695
29	1005793
30	1005925

## APÊNDICE C – Fundamentos Computacionais.

### C.1 DESCRITORES DE HARALICK

**Tabela 55** – Equações dos Descritores de Haralick.

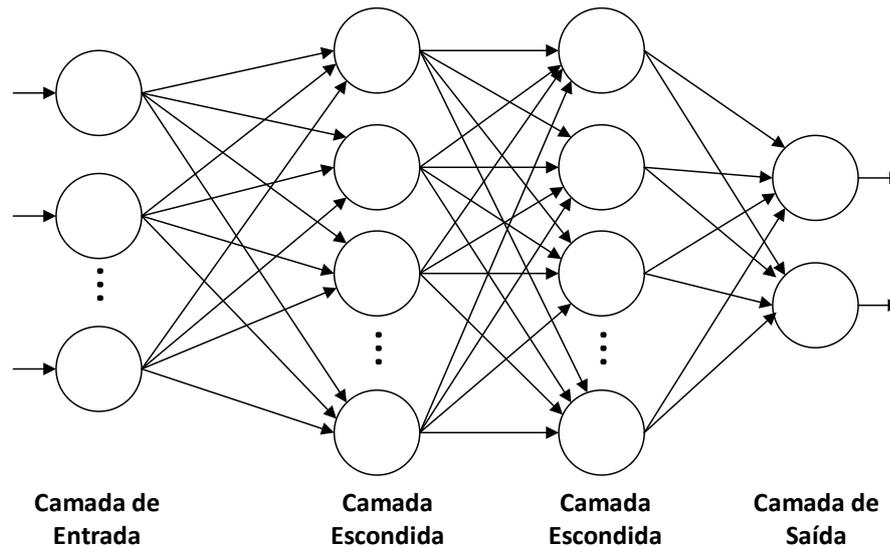
Descritor	Equação
Energia ou Uniformidade	$\sum_i \sum_j p(i, j)^2$
Contraste	$\sum_{n=0}^{N_g-1} n^2 \{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \}$ , $ i - j  = n$ , onde $N_g$ é o número de tons de cinza da imagem.
Correlação	$\frac{\sum_i \sum_j (i - \mu_i)(j - \mu_j)p(i, j)}{\sigma_i \sigma_j}$ , onde $\sigma$ representa o desvio padrão e $\mu$ a média
Soma de Variância	$\sum_i \sum_j (i - \mu)^2 p(i, j)$
Momento da Diferença Inversa	$\sum_i \sum_j \frac{1}{1+(i-j)^2} p(i, j)$
Média da Soma	$\sum_{i=2}^{2N_g} i p_{x+y}(i)$ , onde $x$ e $y$ são as coordenadas (linha e coluna) na matriz de co-ocorrência, $p_{x+y}(i)$ é a probabilidade das coordenadas da matriz de co-ocorrência somadas para $x + y$ .
Variância da Soma	$\sum_i \sum_j (i - \mu)^2 p(i, j)$
Entropia da Soma	$-\sum_{i=2}^{2N_g} (i - Entropia)^2 p_{x+y}(i)$
Entropia	$-\sum_i \sum_j p(i, j) \log(p(i, j))$
Variância da Diferença	$\sum_{i=0}^{N_g-1} i^2 p_{x-y}(i)$
Entropia da Diferença	$-\sum_{i=0}^{N_g-1} p_{x-y}(i) \log\{p_{x-y}(i)\}$
Medida de Informação de Correlação 1	$\frac{HXY - HXY1}{\max(HX, HY)}$
Medida de Informação de Correlação 2	$(1 - \exp[-2(HXY2 - HXY)])^{\frac{1}{2}}$ , onde $HXY = -\sum_i \sum_j p(i, j) \log(p(i, j))$ , $HX$ e $HY$ são as entropias de $p_x$ e $p_y$ , $HXY1 = -\sum_i \sum_j p(i, j) \log(p_x(i)p_y(j))$ e $HXY2 = -\sum_i \sum_j p_x(i)p_y(j) \log(p_x(i)p_y(j))$ .

### C.2 MULTILAYER PERCEPTRON

Uma MLP, também chamado de Perceptron de múltiplas camadas, é um tipo de RNA, como descrito por Levine e IV (2013), que mapeia um conjunto de entradas em um conjunto de saídas. Uma RNA é um modelo matemático que se assemelha às estruturas neurais biológicas e que tem capacidade computacional adquirida por meio de aprendizagem e generalização. Esse modelo assemelha-se com o sistema nervoso dos seres vivos, devido aos seus componentes estruturais, chamados neurônios e sua capacidade de processar informações. A arquitetura da rede é definida pela forma na qual esses neurônios estão organizados e interconectados, sendo definido por: número de neurônios por camada, tipos de conexão entre neurônios e a topologia da rede.

Uma RNA do tipo MLP é constituída por um conjunto de nós de entrada, os quais foram a camada de entrada da rede, uma ou mais camadas escondidas e uma camada de saída. A Figura 115 mostra a arquitetura de uma rede MLP com uma camada de entrada, duas camadas escondidas e uma camada de saída.

**Figura 115** – Arquitetura de uma rede neural MLP com duas camadas escondidas.



Fonte: do autor.

O modelo de cada neurônio da MLP inclui uma função de ativação não-linear. Uma forma comumente utilizada de não-linearidade que satisfaz esse requisito é a não-linearidade sigmoideal definida pela Equação C.1

$$y_j = \frac{1}{1 + e^{-v_j}}, \quad (\text{C.1})$$

onde  $v_j$  é o potencial de ativação do neurônio  $j$ , definido pela soma ponderada das entradas, e  $y_j$  é a saída do neurônio.

Um dos algoritmos mais utilizados em modelos MLP é *backpropagation*, conforme descrito por Karlik e Olgac (2011). O algoritmo *backpropagation* é um tipo de aprendizado supervisionado, que quando o valor de saída é gerado o erro é calculado e seus valores são retro-propagados da camada de saída para as camadas intermediárias, os pesos são ajustados e os valores são novamente calculados.

Basicamente, o algoritmo *backpropagation* consiste de dois passos através das diferentes camadas da MLP: um passo direto e um passo reverso. No passo direto, um padrão a ser aprendido é aplicado aos nós de entrada da MLP e o seu efeito se propaga através da rede, camada por camada, produzindo na camada de saída a resposta da rede.

Durante o passo reverso, os pesos sinápticos são todos ajustados de acordo com a regra de aprendizado por correção de erro.

Seja o sinal de erro na saída do neurônio  $j$  da camada de saída na iteração  $n$ , definido pela Equação C.2, onde  $e_j(n)$  se refere ao sinal de erro de saída do neurônio  $j$  para a iteração  $n$ ,  $d_j(n)$  se refere à resposta desejada para o neurônio  $j$ , e  $y_j(n)$  se refere ao sinal encontrado na saída do neurônio  $j$ .

$$e_j(n) = d_j(n) - y_j(n). \quad (\text{C.2})$$

O valor instantâneo da soma dos erros quadráticos  $\varepsilon(n)$  é obtida somando  $\frac{1}{2}e_j^2(n)$  sobre todos os neurônios de saída. A soma instantânea dos erros quadráticos na camada de saída é descrita pela Equação C.3.

$$\varepsilon(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n), \quad (\text{C.3})$$

onde o conjunto  $C$  inclui todos os neurônios na camada de saída.

O método de correção dos pesos sinápticos é denominado Regra Delta, que é definida pela Equação C.4.

$$\Delta w_{ji}(n) = -\eta \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)}, \quad (\text{C.4})$$

onde  $\Delta w_{ji}$  é a correção aplicada ao  $i$ -ésimo peso do neurônio  $j$ ,  $\eta$  é a taxa de aprendizado do algoritmo e  $w_{ji}(n)$  é o peso que conecta a saída do neurônio  $i$  à entrada do neurônio  $j$ , na iteração  $n$ .