



Universidade Federal de Uberlândia
Faculdade de Engenharia Elétrica
Graduação em Engenharia Biomédica

BRUNO AUGUSTO MACHADO GOES

**ANÁLISE DA SEGMENTAÇÃO DE LESÕES MAMÁRIAS POR *WATERSHED* COM
VARIAÇÃO DE ELEMENTOS ESTRUTURANTES**

Uberlândia
2021

BRUNO AUGUSTO MACHADO GOES

ANÁLISE DA SEGMENTAÇÃO DE LESÕES MAMÁRIAS POR *WATERSHED* COM
VARIAÇÃO DE ELEMENTOS ESTRUTURANTES

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

Orientador: Ana Cláudia Patrocínio

Assinatura do Orientador

Uberlândia
2021

Dedico esse trabalho à minha avó, mãe e irmãs,
por todo apoio, incentivo e compreensão
durante a graduação.

AGRADECIMENTOS

A minha orientadora, Dra. Ana Claudia Patrocínio, por ter aceitado o convite de orientação, pelo apoio a este trabalho e por ter me cativado a área de processamento de imagens desde a primeira aula de Imagens Médicas I, em 2018. Nossas conversas de orientação foram essenciais para o meu desenvolvimento acadêmico e pessoal em tempos de pandemia.

À minha mãe, Vanderléia, por ter sido o primeiro exemplo de dedicação e o por sempre ter acreditado em mim, independente do que acontecesse. Em 2004, minha mãe completou a faculdade, após um período muito árduo em nossa vida. Desde então, é meu motivo de orgulho e meu principal modelo, sempre me incentivado a permanecer focado e dedicado a vida acadêmica.

À minha avó materna, Maria, por ter sido minha melhor amiga durante todos esses anos. Nossas conversas semanais foram meu principal incentivo para continuar em frente. Muito obrigado pela compreensão, por ter ficado ao meu lado a todos os momentos, pelas fofocas e por todo amor e carinho.

À minhas irmãs, Livia e Maísa, parceiras de toda a vida, por terem compreendido a minha ausência e permanecerem presentes digitalmente durante todo o percurso universitário. O contato, mesmo que inconstante, foi a motivação para seguir com a graduação e prover um bom exemplo de perseverança e dedicação. Espero que através da minha jornada se sentir motivadas ao caminho científico e a construção de uma sociedade mais justa e igualitária.

Ao meu padrasto André, exemplo de recomeço. Apesar de todas adversidades, se manteve firme e permanece sendo um grande elo na família, com seu jeito divertido e compreensivo. Agradeço pelo destino ter possibilitado sua presença em nossa família e permitido que compartilhássemos tantos momentos incríveis.

Ao meu namorado, por todos esses anos ao meu lado e pelo apoio presencial e emocional em Uberlândia. Caminhar ao seu lado na graduação foi um privilégio que agradeço a todos os momentos.

A todos os amigos que fiz durante a graduação, por terem sido a minha família universitária. Com toda certeza não chegaria ao final da graduação sem o apoio e incentivo dessas pessoas. Por todos os trabalhos em grupo, noites assistindo série, partidas de jogos online, torcidas nas olimpíadas e desabafos, meu muito obrigado.

Por fim, agradeço a mim, pela persistência e coragem durante os últimos anos. Apesar de todas as adversidades e crises pelo caminho, conseguimos chegar ao final. Espero que quando leia esse trabalho futuramente possa sentir o mesmo orgulho que sinto agora.

RESUMO

O câncer de mama é o principal tipo de câncer diagnosticado mundialmente, sendo que uma a cada seis mulheres diagnosticadas com a doença vão a óbito. Para melhorar o prognóstico e a sobrevivência das pacientes é necessária a detecção precoce através da mamografia. A mamografia é um exame radiográfico que permite observar lesões mamárias como nódulos e calcificações. Através do processamento digital das imagens mamográficas, é possível melhorar a visualização das estruturas e facilitar o diagnóstico, utilizando filtros de suavização de ruído, realce do contraste e segmentação. A segmentação é a divisão da imagem em regiões de interesse (lesões) e fundo da imagem. Uma das técnicas de segmentação é a segmentação por *watershed*, que consiste na análise topográfica da imagem e extração das fronteiras dos objetos da imagem. A segmentação por *watershed* utiliza marcadores, que limitam as regiões que passarão pelo processamento, atenuando problemas como a supersegmentação. Os marcadores podem ser definidos com a utilização de operadores morfológicos, os quais fazem uso de elementos estruturantes para identificar os pixels de interesse. Desse modo, o objetivo desse trabalho é avaliar a segmentação por *watershed* de lesões mamárias, variando o pré-processamento e os elementos estruturantes utilizados. Foram empregados elementos estruturantes nos formatos *diamond* e *disk*, nos tamanhos 25, 50 e 100 pixels, além da suavização do ruído pelo filtro de Wiener e realce de contraste utilizando a transformada *Wavelet* e equalização de histograma adaptativa com limitação de contraste (CLAHE). Os resultados foram avaliados através da acurácia, curva ROC (*Receiver Operating Characteristic Curve*) e análise visual das imagens, com comparação dos resultados obtidos com a imagem original. Como resultado, identificou-se que há relação entre o tamanho e tipo de pré-processamento com o número de regiões detectadas. Além disso, elementos estruturantes menores são mais efetivos na segmentação por *watershed*, sendo necessário pesquisas associando diferentes métodos de redução de ruído e definição de marcadores. Por fim, foi possível estabelecer a interferência da densidade mamária e da forma, tamanho e tipo de lesão no resultado da segmentação.

Palavras-Chave: Câncer de mama. Mamografia. Segmentação. *Watershed*.

ABSTRACT

Breast cancer is the main type of cancer diagnosed worldwide, with one in six women diagnosed with the disease dying. To improve the prognosis and survival of patients is necessary to perform the early detection through mammography. Mammography is a radiographic exam that allows to note mammary lesions as masses and calcifications. Using digital mammographic images processing, it's possible to improve visualization of structures and facilitate diagnosis, using noise-reduction filters, contrast enhancement and segmentation. Segmentation is the division of the image in regions of interest (lesions) and background. One of the techniques in segmentation is watershed segmentation, that is a topographic analysis of the image and object's boundaries extraction. Watershed demands using markers, that limits the regions where processing will be applied, avoiding issues as over-segmentation. The markers can be defined using morphological operators, which uses structuring elements to identify interest pixels. Therefore, the aim of this work is to evaluate watershed segmentation of mammographic lesions, by changing the pre-processing and structuring elements. There were applied disk and diamond-shaped structuring elements, with 25, 50 and 100 pixels as size, in addition to noise-reduction Wiener filter and contrast enhancement with Wavelet transform and contrast limited adaptative histogram equalization (CLAHE). The results were evaluated by using accuracy, ROC curve (Receiver Operating Characteristic Curve) and visual analysis of the images, comparing the results with the original image. As result, it was possible to identify the relationship between size and pre-processing with the number of detected regions. Moreover, small structuring elements are more effective in watershed segmentation, requiring research with different noise reduction methods and marker definition algorithms. Finally, the results allowed to establish how breast density and shape, size and type of lesion interfere in watershed segmentation results.

Keywords: Breast cancer. Mammography. Segmentation. Watershed.

LISTA DE ILUSTRAÇÕES

Figura 1 - Elementos estruturantes <i>disk</i> e <i>diamond</i> de tamanho 4 pixels.....	22
Figura 2 - Etapas desenvolvidas para o processamento das imagens.....	33
Figura 3 - Resultados do pré-processamento das imagens. (a) Original; (b) Filtro de Wiener; (c) <i>Wavelet</i> + CLAHE; (d) Original; (e) Filtro de Wiener; (f) <i>Wavelet</i> + CLAHE....	37
Figura 4 - Resultado da segmentação por <i>watershed</i> com o formato <i>disk</i> . (a) Original; (b) Original + <i>disk</i> 25; (c) Original + <i>disk</i> 50; (d) Original + <i>disk</i> 100; (e) Wiener; (f) Wiener + <i>disk</i> 25; (g) Wiener + <i>disk</i> 50; (h) Wiener + <i>disk</i> 100; (i) <i>Wavelet</i> + CLAHE; (j) <i>Wavelet</i> + CLAHE + <i>disk</i> 25; (k) <i>Wavelet</i> + CLAHE + <i>disk</i> 50; (l) <i>Wavelet</i> + CLAHE + <i>disk</i> 100.	39
Figura 5 - Resultado da segmentação por <i>watershed</i> com o formato <i>disk</i> . (a) Original; (b) Original + <i>disk</i> 25; (c) Original + <i>disk</i> 50; (d) Original + <i>disk</i> 100; (e) Wiener; (f) Wiener + <i>disk</i> 25; (g) Wiener + <i>disk</i> 50; (h) Wiener + <i>disk</i> 100; (i) <i>Wavelet</i> + CLAHE; (j) <i>Wavelet</i> + CLAHE + <i>disk</i> 25; (k) <i>Wavelet</i> + CLAHE + <i>disk</i> 50; (l) <i>Wavelet</i> + CLAHE + <i>disk</i> 100.	40
Figura 6 - Resultado da segmentação por <i>watershed</i> com o formato <i>diamond</i> . (a) Original; (b) Original + <i>diamond</i> 25; (c) Original + <i>diamond</i> 50; (d) Original + <i>diamond</i> 100; (e) Wiener; (f) Wiener + <i>diamond</i> 25; (g) Wiener + <i>diamond</i> 50; (h) Wiener + <i>diamond</i> 100; (i) <i>Wavelet</i> + CLAHE; (j) <i>Wavelet</i> + CLAHE + <i>diamond</i> 25; (k) <i>Wavelet</i> + CLAHE + <i>diamond</i> 50; (l) <i>Wavelet</i> + CLAHE + <i>diamond</i> 100.	41
Figura 7 - Resultado da segmentação por <i>watershed</i> com o formato <i>diamond</i> . (a) Original; (b) Original + <i>diamond</i> 25; (c) Original + <i>diamond</i> 50; (d) Original + <i>diamond</i> 100; (e) Wiener; (f) Wiener + <i>diamond</i> 25; (g) Wiener + <i>diamond</i> 50; (h) Wiener + <i>diamond</i> 100; (i) <i>Wavelet</i> + CLAHE; (j) <i>Wavelet</i> + CLAHE + <i>diamond</i> 25; (k) <i>Wavelet</i> + CLAHE + <i>diamond</i> 50; (l) <i>Wavelet</i> + CLAHE + <i>diamond</i> 100.	42
Figura 8 - Exemplos de curvas ROC geradas para análise da performance do sistema. a) Filtro de Wiener + <i>disk</i> 25 b) Filtro de Wiener + <i>diamond</i> 25	47
Figura 10 - Exemplos de diferenças entre as formas da lesão detectada. (a) Imagem original + <i>disk</i> 25; (b) Wiener + <i>disk</i> 25; (c) <i>Wavelet</i> + CLAHE + <i>disk</i> 25; (d) Imagem original + <i>diamond</i> 25; (e) Wiener + <i>diamond</i> 25; (f) <i>Wavelet</i> + CLAHE + <i>diamond</i> 25.	48
Figura 11 - Exemplos de diferenças entre as formas da lesão detectada. (a) Imagem original + <i>disk</i> 25; (b) Wiener + <i>disk</i> 25; (c) <i>Wavelet</i> + CLAHE + <i>disk</i> 25; (d) Imagem original + <i>diamond</i> 25; (e) Wiener + <i>diamond</i> 25; (f) <i>Wavelet</i> + CLAHE + <i>diamond</i> 25.	49
Figura 12 - Imagens segmentadas após a filtragem com o filtro de Wiener. (a) Wiener + <i>disk</i> 25; (b) Wiener + <i>diamond</i> 25; (c) Wiener + <i>disk</i> 25; (d) Wiener + <i>diamond</i> 25.....	50

Figura 13 - Imagens segmentadas após a filtragem com o filtro de Wiener. (a) Wiener + *disk* 25; (b) Wiener + *diamond* 25; (c) Wiener + *disk* 25; (d) Wiener + *diamond* 25..... 51

LISTA DE TABELAS

Tabela 1 - Tabela de contingência.....	28
Tabela 2 - Processamentos realizados	35
Tabela 3 - Número médio de regiões segmentadas para cada processamento realizado	43
Tabela 4 - Resultados encontrados após a segmentação das imagens	45

LISTA DE ABREVIATURAS E SIGLAS

AUC	<i>Area Under Curve</i>
BI-RADS	<i>Breast Imaging Reporting and Data System</i>
CC	Crânio-caudal
CLAHE	<i>Contrast Limited Adaptive Histogram Equalization</i>
DICOM	<i>Digital Imaging and Communications in Medicine</i>
FFDM	<i>Full Field Digital Mammography</i>
FN	Falso-negativo
FP	Falso-positivo
INCA	Instituto Nacional de Câncer
MATLAB	<i>MATrix LABoratory</i>
MLO	Médio Lateral Oblíqua
MSE	<i>Mean Squarred Error</i>
OMS	Organização Mundial da Saúde
PCA	<i>Principal Composed Analysis</i>
ROC	<i>Receiver Operating Characteristic</i>
SNR	<i>Signal-to-noise Ratio</i>
VN	Verdadeiro-negativo
VP	Verdadeiro-positivo

SUMÁRIO

1. INTRODUÇÃO.....	12
1.1. Objetivo	13
2. IMAGEM MAMOGRÁFICA	14
3. PROCESSAMENTO DIGITAL DE IMAGENS	17
3.1. Pré-processamento	19
3.1.1. Filtro de Wiener	19
3.1.2. Wavelet.....	20
3.1.3. CLAHE.....	21
3.2. Definição dos Marcadores	22
3.2.1. Erosão e Dilatação.....	22
3.2.2. Abertura e Fechamento	23
3.2.3. Reconstrução Morfológica	24
3.3. Segmentação por <i>Watershed</i>	26
4. MÉTRICAS	28
4.1. Curva ROC	28
5. ESTADO DA ARTE	30
6. MATERIAIS E MÉTODOS.....	32
6.1. Banco de Imagens	32
6.2. Processamento	32
7. RESULTADOS	37
8. CONCLUSÃO.....	52
9. REFERÊNCIAS	54
APÊNDICE A - Imagens Segmentadas	56

1. INTRODUÇÃO

De acordo com a Organização Mundial da Saúde (OMS), o câncer de mama, em 2020, tornou-se o tipo de câncer mais diagnosticado mundialmente, chegando a cerca de 2.3 milhões de novos casos. Além disso, uma a cada seis mulheres diagnosticadas com câncer de mama vão ao óbito devido a complicações da doença.

Enquanto isso, no Brasil, as estimativas do Instituto Nacional do Câncer (INCA) calculam cerca de 66.280 novos casos de câncer de mama feminina para 2020. Esse número representa 29,7% de todos os casos de neoplasias detectados, excetuando as de pele não melanoma. A taxa de mortalidade brasileira, em 2019, foi de 16,4%.

Observando esse cenário, o principal meio para melhorar o prognóstico e a sobrevivência das mulheres diagnosticadas com câncer de mama é a detecção precoce. Para isso, o Ministério da Saúde recomenda que mulheres entre 50 e 69 anos realizem mamografia de rastreamento a cada dois anos. A mamografia é um exame radiológico realizado em um mamógrafo e é capaz de detectar alterações nas mamas antes do surgimento dos sintomas relacionados ao câncer. A detecção precoce permite que o tratamento comece mais cedo e seja menos agressivo com a paciente (INCA, 2021).

A imagem mamográfica, como outras imagens radiográficas, está submetida a diversas características indesejáveis que podem dificultar a visualização de características importantes do tecido mamário. Alguns desses problemas são a presença de ruído e baixo contraste entre as estruturas. Tais características podem ser amenizadas através do processamento digital das imagens, através de operações matemáticas que alteram os níveis de intensidade dos pixels e facilitam a visualização pelo radiologista (GONZALEZ, WOODS, 2010; DOUGHERTY, 2009).

Dada a importância da detecção precoce para o tratamento das mulheres acometidas pelo câncer de mama, diversos estudos são realizados com o objetivo de facilitar o diagnóstico. Nesse cenário, as ferramentas computacionais são grandes aliadas, principalmente na área de segmentação, processamento capaz de separar estruturas de interesse, como nódulos e microcalcificações, do restante da imagem. A segmentação, quando realizada corretamente, auxilia na detecção de lesões, permitindo ao radiologista visualizar estruturas que poderiam passar despercebidas (DOUGHERTY, 2009; PANDEY, LALCHHANHIMA, 2020; GOCERI, 2019).

Além disso, outra aplicação da segmentação é na área de classificação automática de lesões mamárias. Um sistema de reconhecimento, geralmente, possui a segmentação como primeiro passo. Com as estruturas de interesse são separadas do restante da imagem, pode-se adquirir algumas características, como tamanho e formato, muito úteis na classificação dos objetos (DOUGHERTY, 2009, PANDEY, LALCHHANHIMA, 2020; GOCERI, 2019).

1.1. Objetivo

O objetivo desse trabalho é avaliar a segmentação de lesões mamárias utilizando a técnica *watershed*, observando a variação do resultado com a alteração do pré-processamento realizado e dos elementos estruturantes utilizados na definição dos marcadores.

Objetivos específicos:

- Avaliar a influência do pré-processamento na segmentação por *watershed*;
- Testar formatos de elementos estruturantes;
- Testar diferentes tamanhos de marcadores.

2. IMAGEM MAMOGRÁFICA

A mamografia é um exame radiográfico, ou seja, utiliza raios X como método de obtenção da imagem. Para isso, é necessário a utilização de um mamógrafo, um equipamento capaz de gerar um feixe de raios X, direcioná-lo e detectar sua absorção pelo tecido mamário (DOUGHERTY, 2009).

A formação do feixe de raios X envolve o aquecimento de um cátodo, geralmente de tungstênio, que libera elétrons através de excitação térmica. Aplicando uma tensão entre 15 e 35 kV no tubo, valores utilizados em mamógrafos, os elétrons são acelerados e direcionados a um ânodo, o alvo que produz os raios X com o impacto. A região do alvo na qual ocorre a produção dos raios X é chamada de ponto focal, sendo um aspecto importante na qualidade do feixe e, conseqüentemente, da imagem. O tubo onde ocorre esse processo é submetido a vácuo, garantindo que os elétrons não percam energia cinética durante o deslocamento (BUSHBERG et al., 2011; DOUGHERTY, 2009).

Desse modo, a energia cinética máxima de um elétron liberado pelo cátodo é equivalente a tensão aplicada no tubo, porém denotada na unidade eV. Durante a produção dos raios X, o elétron perde energia cinética, transformada em calor, sendo que apenas 1% da energia total é convertida em radiação. O feixe é então direcionado para fora do tubo através de uma janela de berílio, passando também por um filtro constituído de uma fina camada de alumínio, molibdênio, ródio ou prata, cujo objetivo é remover os fótons de baixa energia que não são utilizados na formação da imagem pois são incapazes de penetrar os tecidos do paciente (BUSHBERG et al., 2011; DOUGHERTY, 2009).

Existem dois parâmetros essenciais, controlados pelo operador do equipamento, que alteram a qualidade e a quantidade dos fótons produzidos, são eles a tensão aplicada no tubo (kV) e a corrente utilizada para aquecer o filamento (mA). O primeiro altera a energia dos fótons, modificando a capacidade de penetração do feixe. Já a corrente modifica o número de elétrons produzidos no cátodo e, dessa forma, o número de fótons de raios X emitidos pelo ânodo (DOUGHERTY, 2009).

Os fótons de raios X podem interagir de duas maneiras ao atingir o corpo humano, sendo elas a absorção fotoelétrica e o espalhamento Compton. Na absorção fotoelétrica, a energia do fóton é absorvida, causando a liberação de um elétron da camada mais interna do átomo e atenuando o feixe, sendo que essa interação é responsável pela formação da imagem. No caso do espalhamento Compton, parte da energia do fóton é utilizada na ejeção do elétron

e a trajetória do fóton é alterada, causando perda na qualidade da imagem devido a ruído e borramento (BUSHBERG et al., 2011; DOUGHERTY, 2009).

Para que a imagem seja formada, os fótons devem atingir o detector, que converte a energia do fóton em luz visível. A energia do fóton, atenuada ou não, é proporcional à luz produzida, alterando os níveis de cinza presentes na imagem. Caso a energia seja completamente absorvida pelo corpo, através do efeito fotoelétrico, o fóton não contribuirá para a formação da imagem, apenas aumentará a dose do paciente. Em sistemas digitais, que utilizam semicondutores para detecção, é realizada a conversão da energia do fóton em sinal elétrico de forma direta (BUSHBERG et al., 2011; DOUGHERTY, 2009).

Para atenuar os efeitos do espalhamento dos fótons, é possível posicionar uma grade antiespalhamento entre o paciente e o detector. Essa grade, composta de chumbo combinado com alumínio ou carbono, permite que apenas os fótons paralelos atinjam o detector, evitando que os fótons com trajetórias alteradas sejam utilizados na formação da imagem. Tal efeito ocorre devido às características absorvedoras de radiação do chumbo (DOUGHERTY, 2009).

O detector é responsável por captar os fótons atenuados ou não para formar a imagem. Podem ser utilizadas diversas modalidades como filmes e cassetes radiográficos e detectores semicondutores. No caso dos semicondutores, a imagem produzida é digital, resultando em melhor qualidade e maior facilidade no processamento e armazenamento (DOUGHERTY, 2009).

Sintetizando, dentre as particularidades de um mamógrafo estão: operação em tensões mais baixas (entre 15 e 35 kV), utilização de ânodo e filtros de molibdênio e ponto focal entre 0.1 e 0.3 mm. Aplicar menor tensão no tubo tende a melhorar o contraste, pois a absorção fotoelétrica é mais eficiente em raios X com menor energia. Entretanto, baixas energias são mais facilmente absorvidas, aumentando a dose do paciente (BUSHBERG et al., 2011; DOUGHERTY, 2009).

Além disso, para a detecção de uma imagem de boa qualidade, é necessário que a mama seja comprimida. A compressão permite a redução do espalhamento dos fótons, uniformizar a exposição da mama e, conseqüentemente, diminuir o borramento da imagem. Também é importante ressaltar que, com a compressão da mama, artefatos de movimento e sobreposição dos tecidos mamários são diminuídos (DOUGHERTY, 2009; POULOS et al., 2003).

Para que o exame seja completo, é necessário que sejam adquiridas duas imagens de cada mama, cada imagem com um posicionamento. Na incidência médio lateral oblíqua (MLO) a paciente é posicionada paralelamente ao plano, variando a angulação do tubo entre 30° e 60° para expor o tecido mamário e a região axilar. Já na incidência craniocaudal (CC), o tubo é posicionado verticalmente, com o feixe sendo emitido perpendicular à mama. A vista CC permite visualizar as partes lateral e medial da mama, além do músculo grande peitoral (BRASIL, 2007).

Através do exame mamográfico, pode-se detectar diversos achados suspeitos, indicativos de câncer de mama ou não, entre eles nódulos, microcalcificações, assimetrias, distorções focais e dilatações ductais. Tais lesões podem apresentar muitas formas, tamanhos, contornos e densidades diferentes, fato que dificulta a análise por sistemas computacionais. (BRASIL, 2007; SICKELS, 2013).

Outra característica a ser observada na mamografia é a densidade da mama. A descrição da composição da mama é dada segundo a substituição do parênquima mamário pelo tecido adiposo. Desse modo, as mamas podem ser classificadas em densas (sem substituição adiposa), predominantemente densas, predominantemente adiposas e adiposas (contendo apenas tecido adiposo). A densidade da mama é de extrema importância na avaliação do exame mamográfico, pois, devido a atenuação dos raios X, lesões e tecido fibroglandular possuem intensidades muito parecidas na imagem, dificultando a visualização e o diagnóstico (BRASIL, 2007; SICKELS, 2013).

3. PROCESSAMENTO DIGITAL DE IMAGENS

Devido à natureza das imagens mamográficas, algumas características podem afetar o resultado, dificultando a visualização, interpretação e qualidade do diagnóstico. Dentre os principais problemas podemos citar a presença de ruído e baixo contraste entre as estruturas. Dito isso, podemos considerar que a primeira etapa no processamento de imagens radiológicas é a filtragem, que tem como objetivo melhorar a qualidade da imagem adquirida, suavizando ruídos e aumentando o contraste entre as regiões de interesse (BANKMAN, 2009; GONZALEZ, WOODS, 2010).

Como segunda etapa no processamento de imagens digitais, temos a segmentação. Esse processo é definido pela identificação e extração de estruturas de interesse na imagem, diferenciando-as do fundo. Em imagens mamográficas os objetos a serem encontrados na segmentação são, geralmente, lesões como nódulos e microcalcificações, na intenção de identificar indícios de câncer de mama. Esse processo é utilizado como método de auxílio ao diagnóstico, sendo uma ferramenta útil na identificação e classificação automática de nódulos, por exemplo (BANKMAN, 2009; GONZALEZ, WOODS, 2010).

Segundo Dougherty (DOUGHERTY, 2009), podemos classificar os algoritmos de segmentação em dois tipos: técnicas baseadas no contexto e abordagens que ignoram o contexto da imagem. O primeiro tipo leva em consideração as relações entre as estruturas da imagem, agrupando pixels com níveis de intensidade parecidos, por exemplo. Já o segundo, agrupa os pixels baseado unicamente em algum atributo global, como o nível de cinza (DOUGHERTY, 2009).

O processo de segmentação é uma das tarefas mais difíceis no processamento de imagens, sendo uma área com grande quantidade de pesquisas em desenvolvimento. Os algoritmos de segmentação procuram operar nas variações de intensidade e textura para identificar regiões semelhantes. Dentre as técnicas de segmentações temos a limiarização, crescimento de regiões e *watersheds* morfológicas. (BANKMAN, 2009; GONZALEZ, WOODS, 2010; PANDEY, LALCHHANHIMA, 2020).

No processamento de imagens digitais, definimos uma imagem como uma função $f(x, y)$, na qual x e y são as coordenadas espaciais e f representa a intensidade nesse ponto. Em termos de processamento digital, a melhor maneira de representar uma imagem é através de uma matriz numérica $M \times N$, que correspondem, respectivamente, ao número de linhas e colunas da matriz. Cada elemento da matriz constitui um elemento de imagem, chamado de

pixel, possuindo uma coordenada espacial e um valor de intensidade ou nível de cinza associado. Podemos representar essa matriz como (GONZALEZ, WOODS, 2010):

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

A quantidade de níveis de cinza que podem estar presentes em uma imagem está diretamente relacionado ao número de *bits* necessários para armazená-la. Esse número também é referido como resolução de intensidade, definida como a menor variação discernível de nível de intensidade na imagem. Dessa forma, sendo n o número de *bits* da imagem, a quantidade de níveis de intensidade é igual a 2^n . Por exemplo, uma imagem de 8 *bits* de resolução apresenta 256 tons de cinza disponíveis para exibição (GONZALEZ, WOODS, 2010).

Os pixels de uma imagem se relacionam entre si de diversas maneiras. Considerando p como um pixel na coordenada (x, y) , chamamos de vizinhança-4 os pixels presentes nas coordenadas $(x+1, y)$, $(x-1, y)$, $(x, y+1)$, $(x, y-1)$. Já a vizinhança-8, inclui os pixels das vizinhança-4 e os vizinhos diagonais presentes nas coordenadas $(x+1, y+1)$, $(x+1, y-1)$, $(x-1, y+1)$, $(x-1, y-1)$. O conceito de vizinhança é muito útil ao se tratar de processamentos no domínio espacial, ou seja, que levam em consideração as coordenadas de posicionamento dos pixels (GONZALEZ, WOODS, 2010).

As conexões entre um pixel e seus vizinhos também são importantes na detecção de fronteiras e bordas. Utilizando a vizinhança-8 de um pixel, podemos definir a fronteira de uma região como o conjunto de pixels da região que possuem pelo menos um vizinho no fundo da imagem. O conceito de borda leva em consideração também as derivadas e um limiar pré-estabelecido, como forma de detectar descontinuidade e variações bruscas de intensidade entre os pixels. Essas definições são relevantes no desenvolvimento de algoritmos de segmentação, auxiliando na detecção de regiões específicas da imagem (GONZALEZ, WOODS, 2010).

Os processamentos da imagem que atuam diretamente nos pixels são as técnicas no domínio espacial. Essas técnicas possibilitam manipular os níveis de intensidade dos pixels, conforme sua vizinhança. Para isso, definimos os processamentos através da seguinte expressão, em que $f(x, y)$ é a imagem de entrada, $g(x, y)$ a imagem de saída e T é o operador a ser aplicado (GONZALEZ, WOODS, 2010):

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

Para realizar um processamento no domínio espacial, definimos uma matriz contendo os coeficientes desejados, sendo essa matriz também chamada de máscara ou *kernel*. Essa máscara é movida por todos pixels da imagem, aplicando o operador T aos pixels da vizinhança. O valor do pixel central é então substituído pelo resultado da operação e, após o processamento em todas as linhas e colunas, a imagem de saída é formada (GONZALEZ, WOODS, 2010).

A seguir trataremos de algumas técnicas das etapas de filtragem e segmentação no processamento de imagens.

3.1. Pré-processamento

3.1.1. Filtro de Wiener

O filtro passa-baixa do tipo Wiener, também conhecido como filtro de mínimo erro quadrático médio, é utilizado como método para suavização de ruídos e restauração de imagens. O mecanismo de processamento visa minimizar o erro quadrático médio de forma a maximizar a relação sinal ruído. Para aplicá-lo é necessário a obtenção dos espectros de frequência do sinal de origem e do ruído, ou seja, é preciso conhecimento prévio do espectro de potência do ruído a ser suavizado (GONZALEZ, WOODS, 2010).

A técnica de Wiener incorpora a função de degradação e as características estatísticas do ruído no processo de restauração. Esse método também considera que a imagem original e o ruído são variáveis aleatórias, tendo por objetivo estimar $\hat{f}(x, y)$ da imagem não corrompida $f(x, y)$, de forma que o erro quadrático médio seja o menor possível. A medida do erro é dada por (DOUGHERTY, 2009; GONZALEZ, WOODS, 2010):

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

Sendo que $E\{\}$ é o valor esperado do argumento. Para encontrar o valor mínimo da função de erro, é preciso presumir inicialmente que: o ruído e a imagem não sejam correlacionados, que possuam a média igual a zero e que a intensidade dos pixels da estimativa sejam uma função linear dos níveis encontrados na imagem degradada. Dessa forma, o mínimo valor da função é dado no domínio da frequência através da expressão (DOUGHERTY, 2009; GONZALEZ, WOODS, 2010):

$$\hat{F}(u, v) = \left[\frac{H^*(u, v)S_f(u, v)}{S_f(u, v)|H(u, v)|^2 + S_f(u, v)} \right] G(u, v)$$

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

Os termos dessa equação são:

$H(u, v)$ = função de degradação;

$H^*(u, v)$ = conjugado complexo de $H(u, v)$;

$|H(u, v)|^2 = H^*(u, v)H(u, v)$, ou seja, o produto de um número complexo pelo seu conjugado corresponde à sua magnitude ao quadrado;

$S_\eta(u, v) = |N(u, v)|^2$ = espectro de potência do ruído;

$S_f(u, v) = |F(u, v)|^2$ = espectro de potência da imagem não degradada.

Considerando que o resultado da filtragem é uma função no domínio da frequência, para encontrarmos a imagem restaurada é necessário realizar a transformada inversa de Fourier da estimativa $\hat{F}(u, v)$ (DOUGHERTY, 2009; GONZALEZ, WOODS, 2010).

3.1.2. Wavelet

A transformada *wavelet* é um método utilizado para realce de contraste e suavização de ruídos que divide a imagem em várias subimagens, decompondo o sinal em diferentes escalas, no domínio da frequência e no domínio do tempo. Escolhendo uma *wavelet-mãe*, é possível desenvolver divisões através da dilação e translação do sinal, possibilitando a análise multirresolução (CARNEIRO, 2019).

Por meio de um algoritmo proposto por Mallat, é possível obter as aproximações e os detalhes de um sinal através de um algoritmo piramidal (diática). Dessa forma, decompõe-se o sinal em dois termos: um termo correspondente ao coeficiente de aproximação, contendo as componentes de baixas frequências (baixa variação de intensidade); e o coeficiente de detalhe, que pode ser subdividido nas direções vertical, horizontal e diagonal. Portanto, através desse método, obtém-se quatro níveis de decomposição: aproximação, vertical, horizontal e diagonal (CARNEIRO, 2019).

Como os ruídos são majoritariamente representados como baixas frequências, é possível reduzi-los através da limiarização, também chamada de *thresholding*, dos coeficientes adquiridos na transformada *wavelet*. Realizando o truncamento através de um limiar pré-estabelecido, elimina-se os níveis de intensidade menores que os valor delimitado. Após a

limiarização, realiza-se a transformada *wavelet* inversa nos coeficientes de aproximação e detalhe, obtendo-se a imagem filtrada (CARNEIRO, 2019).

Além da limiarização para suavização de ruídos, pode-se implementar técnicas de realce de contraste no domínio *wavelet*. Para isso, manipula-se os parâmetros detectados no coeficiente de detalhe antes da aplicação da transformada *wavelet* inversa. O resultado é uma imagem com melhor qualidade visual que permite a diferenciação entre objetos de interesse e o fundo (CARNEIRO, 2019).

3.1.3. CLAHE

O método chamado *Contrast-limited Adaptive Histogram Equalization* (CLAHE) é uma técnica indireta de modificação de contraste, ou seja, ela altera as configurações do histograma da imagem. A CLAHE foi inicialmente proposta por Pizer e tem como método o ajuste do histograma original tomando como base um histograma pré-definido. Dessa forma, os valores excedentes são redistribuídos em outras intensidades, sendo essa técnica uma forma adaptativa da equalização de histograma (CARNEIRO et al, 2019).

Alguns parâmetros precisam ser definidos para aplicação da CLAHE, a quantidade de janelas em que a imagem será dividida. O número de janelas altera diretamente a qualidade da equalização, sendo que quanto maior a janela, menor a qualidade. Outra questão é o limite de corte, definido entre 0 e 1, que delimita o número de pixels que serão redistribuídos (CARNEIRO et al, 2019).

Por fim, é preciso escolher a distribuição de probabilidade que será utilizada para rearranjo dos pixels. A tendência é que o histograma da imagem de saída seja correspondente ao formato da função aplicada. Como exemplo de funções utilizadas na literatura temos a função uniforme, exponencial e Rayleigh. A equação a seguir estabelece o procedimento utilizado para aplicação da CLAHE (CARNEIRO et al, 2019).

$$g = [g_{max} - g_{min}]p(f) + g_{min} \quad (5)$$

Sendo que g indica o resultado do processamento para cada pixel, g_{max} e g_{min} , os máximos e mínimos valores de intensidade do pixel e $p(f)$ é a função de distribuição de probabilidade escolhida (CARNEIRO et al, 2019).

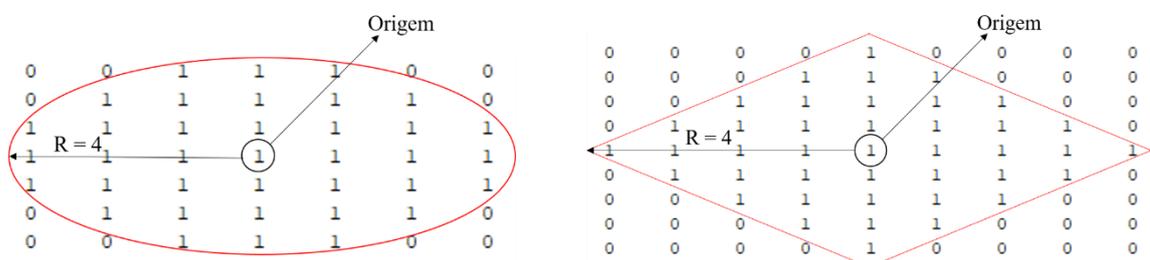
3.2. Definição dos Marcadores

A segmentação por *watershed* utiliza potenciais pixels com valor características de mínimos regionais como ponto de partida para o processamento. Portanto, uma imagem com muito mínimos regionais potenciais pode ter como resultado a supersegmentação, que consiste na segmentação de muitas regiões irrelevantes na imagem. Para evitar esse problema, pode-se utilizar algumas operações morfológicas e definir marcadores, limitam os pixels a serem utilizados como mínimos regionais (DOUGHERTY, 2009; GONZALEZ, WOODS, 2010; PANDEY, LALCHHANHIMA, 2020; SANTOS, 2002).

As operações morfológicas são estratégias de processamento do tipo não linear que são utilizadas para extrair e modificar o formato e a estrutura de objetos na imagem. Esses operadores são utilizados na suavização de ruídos, detecção de bordas, detecção de estruturas e segmentação. Alguns operadores morfológicos utilizados no processamento de imagens são a erosão, dilatação, abertura, fechamento e reconstrução morfológica (DOUGHERTY, 2009; GONZALEZ, WOODS, 2010).

Para aplicação das operações morfológicas é necessário a definição de um elemento estruturante, que consiste em uma máscara binária com forma e tamanho escolhido de acordo com o objetivo. O elemento estruturante analisa a região entorno do pixel central e apenas os pixels cuja região se encaixam perfeitamente na máscara serão computados no resultado. É importante ressaltar que o método do elemento estruturante depende da operação morfológica utilizada. A Figura 1 exemplifica dois elementos estruturantes nos formatos *disk* e *diamond* e com tamanho de quatro pixels (DOUGHERTY, 2009; GONZALEZ, WOODS, 2010).

Figura 1 - Elementos estruturantes *disk* e *diamond* de tamanho 4 pixels



Fonte: Elaborado pelo autor

3.2.1. Erosão e Dilatação

Uma das operações morfológicas utilizadas no processamento de imagens é a erosão. A erosão procura identificar os objetos menores que o elemento estruturante e eliminá-los,

diminuindo e afinando as estruturas da imagem. O elemento estruturante de é sobreposto a imagem e, se algum pixel coincidir com a máscara definida, ele é rejeitado no resultado. Matematicamente, podemos definir a erosão como (DOUGHERTY, 2009; GONZALEZ, WOODS, 2010):

$$A \ominus B = \{z \mid (B)_z \cap A^c = \emptyset\} \quad (6)$$

Sendo que A representa a imagem e B o elemento estruturante utilizado para buscar as propriedades de interesse. Para análise apropriada da Equação (6), é preciso definir algumas operações como a translação e o complemento dos elementos. A translação do elemento estruturante, representada por $(B)_z$, ocorre quando as coordenadas (x, y) do elemento são substituídas por $(x + z_1, y + z_2)$. Já o complemento da imagem, aqui representado por A^c , refere-se aos pixels que não pertencem ao conjunto inicial A (GONZALEZ, WOODS, 2010).

Assim como a erosão, a dilatação também trata a imagem e o elemento estruturante como conjuntos para realizar a operação. No caso da dilatação, o objetivo é aumentar e engrossar os objetos da imagem, sendo aplicada matematicamente através da Equação (7). A dilatação considera um pixel como parte de uma região se pelo menos um pixel da vizinhança, definida pelo elemento estruturante, coincidir com a máscara definida (DOUGHERTY, 2009; GONZALEZ, WOODS, 2010).

$$A \oplus B = \{z \mid (\hat{B})_z \cap A \neq \emptyset\} \quad (7)$$

Observa-se que a Equação (7) utiliza um outro conceito, a reflexão, aqui representada por \hat{B} . O elemento estruturante é refletido, ou seja, as coordenadas (x, y) são substituídas por $(-x, -y)$ e, após isso, é feita a translação do resultado. Dessa forma, o resultado a operação de dilatação consiste no conjunto de deslocamentos tal que \hat{B} e A possuam ao menos um elemento sobreposto (GONZALEZ, WOODS, 2010).

3.2.2. Abertura e Fechamento

As operações morfológicas de abertura e fechamento aplicam os conceitos de erosão e dilatação da imagem como forma de processamento, visando ressaltar as fronteiras e auxiliar na segmentação de objetos. Para isso, a abertura suaviza as fronteiras dos objetos enquanto o fechamento preenche os buracos do contorno. Matematicamente, definimos a abertura através da Equação (8) (DOUGHERTY, 2009; GONZALEZ, WOODS, 2010).

$$A \circ B = (A \ominus B) \oplus B \quad (8)$$

Ou seja, a abertura da imagem A pelo elemento estruturante B ocorre pela erosão de A por B e a dilatação do resultado por B . Da mesma maneira, o fechamento da imagem acontece pela dilatação de A por B e a erosão do resultado por B , como mostrado na Equação (9) (DOUGHERTY, 2009; GONZALEZ, WOODS, 2010).

$$A \bullet B = (A \oplus B) \ominus B \quad (9)$$

Por utilizarem os princípios de erosão e dilatação, a abertura e o fechamento resultam em uma imagem com características parecidas com os primeiros operadores. Dessa forma, a abertura pode ser utilizada para eliminar objetos irrelevantes e estruturas finas. Já o fechamento é aplicado para restaurar a conectividade entre regiões, sendo desaconselhado quando duas regiões diferentes são localizadas muito próximas uma da outra (DOUGHERTY, 2009).

As bordas são detectadas em duas partes: a abertura detecta a fronteira interna do objeto e o fechamento a fronteira externa. É importante ressaltar que, uma das propriedades dessas operações é que múltiplas aberturas e fechamentos, de uma mesma imagem por um mesmo elemento estruturante, não surtem efeito após a primeira aplicação (GONZALEZ, WOODS, 2010).

3.2.3. Reconstrução Morfológica

A reconstrução morfológica utiliza os conceitos das quatro operações morfológicas básicas para sua aplicação. Ou seja, é possível realizar a reconstrução na erosão, dilatação, abertura e fechamento.

Para a reconstrução morfológica por dilatação, é preciso apresentar o conceito de dilatação geodésica. A dilatação geodésica é definida pela dilatação de uma imagem F pelo elemento estruturante B e a interseção do resultado com a máscara G . Uma dilatação geodésica de tamanho n é demonstrada pela Equação (10) (GONZALEZ, WOODS, 2010).

$$D_G^{(n)}F = D_G^{(1)}[D_G^{(n-1)}(F)] \quad (10)$$

Sendo que o termo $D_G^{(1)}$ garante que a interseção seja feita em todas as etapas, limitando a dilatação da imagem F ao tamanho da máscara G . O termo refere-se à primeira dilatação realizada, que consiste em (GONZALEZ, WOODS, 2010):

$$D_G^{(1)} = (F \oplus B) \cap G \quad (11)$$

A reconstrução morfológica por dilatação consiste na dilatação geodésica da imagem F , utilizando o elemento estruturante B e a máscara G , repetida até que a estabilidade seja alcançada. Podemos analisar essa propriedade através da equação abaixo (GONZALEZ, WOODS, 2010):

$$R_G^D(F) = D_G^{(n)}(F) = D_G^{(n+1)}(F) \quad (12)$$

Da mesma forma, a reconstrução morfológica por erosão consiste na erosão geodésica da imagem F , utilizando o elemento estruturante B e a máscara G , repetida até que a estabilidade seja alcançada. Podemos analisar essa propriedade através da Equação (13) (GONZALEZ, WOODS, 2010).

$$R_G^E(F) = E_G^{(n)}(F) = E_G^{(n+1)}(F) \quad (13)$$

É preciso ressaltar que a erosão geodésica de uma imagem F consiste na erosão de uma imagem F pelo elemento estruturante B e a união do resultado com a máscara G . Para ilustrar matematicamente, as Equações (14) e (15) demonstram os resultados de uma erosão geodésica de tamanho 1 e de tamanho n , respectivamente (GONZALEZ, WOODS, 2010).

$$E_G^{(1)}(F) = (F \ominus B) \cup G \quad (14)$$

$$E_G^{(n)}F = E_G^{(1)}[E_G^{(n-1)}(F)] \quad (15)$$

Ao contrário da abertura morfológica, cuja precisão da reconstrução da imagem é dependente da forma do elemento estruturante, a abertura por reconstrução restaura exatamente a forma dos objetos detectados na erosão. Essa operação consiste na aplicação da reconstrução morfológica por dilatação após a erosão de tamanho n de uma imagem F com um elemento estruturante B (GONZALEZ, WOODS, 2010).

Desse modo, podemos definir a abertura por reconstrução como:

$$O_R^{(n)} = R_F^D[F \ominus nB] \quad (16)$$

Analogamente, o fechamento por reconstrução consiste na reconstrução morfológica por erosão após a dilatação de tamanho n de uma imagem F com um elemento estruturante B . O uso da reconstrução limita a erosão da imagem F ao tamanho da máscara G , reproduzindo as proporções da imagem original (GONZALEZ, WOODS, 2010).

Portanto, podemos definir o fechamento por reconstrução como:

$$C_R^{(n)} = R_F^E[F \oplus nB] \quad (17)$$

3.3. Segmentação por *Watershed*

O objetivo principal da segmentação por *watershed* é extrair as fronteiras dos objetos da imagem, sendo amplamente utilizado pois seu resultado consiste em fronteiras contínuas entre as regiões. Para isso, é necessário visualizar a imagem em três dimensões, em uma visão topográfica, sendo representada por duas coordenadas espaciais e um eixo referente a intensidade dos tons de cinza (DOUGHERTY, 2009; GONZALEZ, WOODS, 2010; PANDEY, LALCHHANHIMA, 2020; SANTOS, 2002).

Analisando dessa forma, é possível identificar três tipos de pontos com características distintas: os pontos correspondentes ao mínimos regionais; os pontos cuja variação de intensidade tendem a um mínimo simples, cujo conjunto forma as *watersheds*; e os pontos que a variação tem a mesma probabilidade de tender a mais de um mínimo regional, formando as linhas de *watershed*. As linhas de *watershed* correspondem as fronteiras dos objetos, ou seja, são os pontos que devem ser extraídos na segmentação (GONZALEZ, WOODS, 2010; BANKMAN, 2009; DOUGHERTY, 2009; SANTOS, 2002).

Para construir as *watersheds*, é possível utilizar a dilatação morfológica como processamento, partindo do conjunto de mínimos regionais da imagem. Se a dilatação ocorrer em pontos que misturem conjuntos dilatados, esse conjunto de pontos é marcado como parte das linhas de *watershed* que correspondem as fronteiras dos objetos encontrados (GONZALEZ, WOODS, 2010; BANKMAN, 2009; DOUGHERTY, 2009; SANTOS, 2002).

Considerando que M_1, M_2, \dots, M_i são os conjuntos contendo as coordenadas dos mínimos regionais, visualizada como a imagem gradiente, e o conjunto conexo de pontos na

watershed de um mínimo regional é $C(M_i)$. Além disso, $T[n]$ representa o conjunto de pontos cuja a intensidade $g(s, t)$ é menor que o valor de intensidade n (GONZALEZ, WOODS, 2010).

Se $C_n(M_i)$ são os pontos da *watershed* que são menores que o valor de intensidade n , podemos dizer que:

$$C_n(M_i) = C(M_i) \cap T[n] \quad (18)$$

Para obtermos todas as *watersheds* encontradas é preciso fazer a união de todos os conjuntos, operação que é denotada por:

$$C[n] = \bigcup_{i=1}^R C_n(M_i) \quad (19)$$

Portanto, quando $n = \text{máx} + 1$, ou seja, o máximo valor de intensidade da imagem acrescido de 1, encontramos a união de todas as *watersheds* da imagem. Encontrando as *watersheds*, o próximo passo é delimitar as linhas de *watershed* e definir as fronteiras. Para isso, a variável n deve ser inicializada como $n = \text{mín} + 1$, ou seja, o menor valor de intensidade da imagem acrescido de 1. Quando um elemento q pertencente a $T[n]$ contém mais de um componente conectado em $C[n - 1]$, ele é marcado utilizando a dilatação $q \cap C[n - 1]$ e um elemento estruturante. O conjunto de elementos q marcados correspondem as *linhas de watershed* (GONZALEZ, WOODS, 2010).

Um dos desafios na aplicação da segmentação por *watershed* é evitar a supersegmentação da imagem. Esse problema ocorre, principalmente, devido ao ruído presente na imagem processada, causando a existência exagerada de mínimos potenciais e levando a formação muitas *watersheds* (DOUGHERTY, 2009; GONZALEZ, WOODS, 2010; PANDEY, LALCHHANHIMA, 2020; SANTOS, 2002).

Como solução, é possível realizar o pré-processamento da imagem, aplicando filtros de suavização como forma de diminuir o ruído existente. Alguns filtros utilizados para esse fim são os filtros de média, mediana, Wiener e processamentos utilizando a transformada *wavelet*. Além disso, pode-se limitar os números de mínimos regionais permitidos e diminuir a quantidade de regiões nas quais a *watershed* é aplicada, utilizando marcadores definidos com base no fundo da imagem (DOUGHERTY, 2009; GONZALEZ, WOODS, 2010; SANTOS, 2002).

4. MÉTRICAS

4.1. Curva ROC

A análise ROC (*Receiver Operating Characteristic*) é um método utilizado para identificar a eficiência do algoritmo quanto detecção ou não de um determinado objeto em uma imagem. No caso da mamografia, podemos tratar um sinal sn como a lesão a ser estudada e o ruído n como o restante da imagem. Através da Tabela 1, podemos identificar quatro possíveis resultados na segmentação de uma imagem. (BRAGA, 2000; RIBEIRO, 2016).

Tabela 1 - Tabela de contingência

		Acontecimento	
		Ruído + Sinal (sn)	Ruído (n)
Resposta	Sim (S)	$a = P(S sn)$ (acerto ou verdadeiro-positivo)	$b = P(S n)$ (falso alarme ou falso-positivo)
	Não (N)	$c = P(N sn)$ (valor omissso ou falso-negativo)	$d = P(N n)$ (verdadeiro-negativo)

Fonte: Braga, 2010.

Por tanto, os resultados podem ser classificados em:

1. $P(S | sn)$: verdadeiro-positivo, correspondente à probabilidade de detecção de uma lesão quando ela realmente existe;
2. $P(S | n)$: verdadeiro-negativo, referente à quando o algoritmo não detecta a lesão e ela não existe na imagem;
3. $P(N | sn)$: falso-positivo, equivalente à probabilidade de detecção de uma lesão quando ela não existe;
4. $P(N | n)$: falso-negativo, referente à não detecção da lesão quando ela existe na imagem.

Levando em consideração essas possibilidades, podemos definir a sensibilidade de um algoritmo como a capacidade de detecção da lesão na imagem, ou seja, o número de verdadeiros positivos. Analogamente, a especificidade corresponde a capacidade de identificar a ausência da lesão quando ela realmente não existe, isto significa o número de verdadeiros negativos do sistema. Dessa forma, a curva ROC representa um gráfico da sensibilidade, no eixo y, *versus* $1 -$ especificidade, no eixo x. O valor utilizado no eixo x representa o número de falsos

positivos e é designado para lidar com a complexidade das variáveis analisadas (PARK, GOO, JO, 2004; RIBEIRO, 2016; SANTOS, 2002).

Matematicamente, podemos definir a sensibilidade e a especificidade como:

$$\text{Sensibilidade} = \frac{P(S | sn)}{P(N | sn) + P(S | sn)} \quad (20)$$

$$\text{Especificidade} = \frac{P(N | n)}{P(N | n) + P(S | n)} \quad (21)$$

Além disso, através da curva ROC, é possível analisar de forma quantitativa a eficiência do sistema. Para isso, utiliza-se a área sob a curva (AUC – *Area Under Curve*) que corresponde a um valor entre 0 e 1. Quanto mais próximo de 1, mais eficiente o sistema observado (RIBEIRO, 2016; SANTOS 2002).

Outra medida utilizada na avaliação das imagens é a Acurácia, parâmetro calculado a partir das informações obtidas no cálculo da curva ROC. A Acurácia mensura a proporção de acertos dentre todas as segmentações. Podemos calculá-la através da Equação 22 (FADIL et al., 2020).

$$\text{Acurácia } a = \frac{TP + TN}{TP + FN + TN + FP} \quad (21)$$

Sendo que, TP corresponde a taxa de verdadeiro-positivos; TN a taxa de verdadeiro-negativos; FN ao número de falso-negativos; e FP a taxa de falso-positivos (FADIL et al., 2020).

5. ESTADO DA ARTE

A pesquisa em segmentação de estruturas de interesse em imagens mamográficas é vasta e composta de diversos métodos. Dentre as técnicas de segmentação comumente aplicadas temos a limiarização global e pelo método de Otsu, crescimento de regiões e *watersheds* morfológicas. No caso da segmentação por *watershed*, indica-se a utilização de marcadores, para evitar problemas como a supersegmentação (DOUGHERTY, 2009; GONZALEZ, WOODS, 2010; PANDEY, LALCHHANHIMA, 2020).

Na pesquisa realizada por Embong e Anuar (EMBONG, ANUAR, 2018), foram analisadas 32 imagens, dividindo-as em regiões de interesse com o objetivo de identificar o elemento estruturante com melhor resultado para aplicações com segmentação por *watershed*. Para definir os marcadores, utilizou-se operações morfológicas com três tipos de elementos estruturantes com formatos disco, diamante e octógono, sendo os dois primeiros de tamanho 20 pixels e o segundo no tamanho 21 pixels.

Além disso, as imagens foram pré-processadas com Análise de Componentes Principais (PCA – *Principal Component Analysis*) para suavização dos ruídos e agrupamento difuso *C-means* (Fuzzy *C-means*) para identificar as regiões de interesse. Como resultado, concluiu-se que as segmentações realizadas com o formato diamante apresentaram menor erro entre a área segmentada e a área de interesse, comprovado pelas métricas *Jaccard Index* e *Dice Similarity Coefficient* (EMBONG, ANUAR, 2018).

Com o mesmo objetivo, LEWIS e DONG (LEWIS, DONG, 2012) utilizaram operações morfológicas pra definir os marcadores antes da segmentação por *watershed*. Para o processamento, foram utilizados a abertura e o fechamento por reconstrução dos máximos regionais da imagem, a fim de detectar nódulos em 48 imagens mamográficas. Por fim, escolheu-se dois marcadores: um interno, com a fronteira da região de interesse; e um externo, após a realização da limiarização adaptativa da imagem seguida da segmentação por *watershed*.

Com os dois marcadores definidos, a segmentação por *watershed* foi aplicada na imagem original apenas na área permitida pelas máscaras. A taxa de acerto do algoritmo foi de 90%. Entretanto, foram detectadas várias regiões segmentadas erroneamente e formatos inconsistentes com a imagem original. Isso significa que se deve aperfeiçoar o algoritmo de seleção dos marcadores, restringindo as regiões em que serão aplicadas a *watershed* de forma a melhorar a qualidade da segmentação (LEWIS, DONG, 2012).

Outros trabalhos também definiram marcadores de regiões antes da segmentação por *watershed*, inclusive em outros tipos de imagem. Na proposta de Manda *et al.*, definiu-se marcadores externos e internos através da limiarização por Otsu para segmentação por *watershed* de imagens infravermelhas. O algoritmo obteve bons resultados comparado com os métodos de Xue e Otsu separadamente (MANDA *et al.*; 2019).

A segmentação de imagens mamográficas pode ser aplicada em algoritmos de classificação de lesões. Esses sistemas são desenvolvidos utilizando redes neurais, treinando o algoritmo para classificar automaticamente uma lesão e auxiliar no diagnóstico de câncer de mama. No trabalho de Al-antari *et al* (AL-ANTARI *et al.*, 2018), foi desenvolvido um sistema de auxílio ao diagnóstico que utiliza redes neurais convolucionais para a segmentação e classificação dos resultados. A precisão do método de segmentação foi de 98,96% enquanto o de classificação apresentou 95,64%, para imagens do banco de dados INBreast.

Além da segmentação por redes neurais, há outras formas de processamentos que objetivam detectar lesões para classificação automática. Fadil *et al* (FADIL *et al.*, 2020), realizou o pré-processamento de 996 imagens utilizando a transformada *wavelet* para aumento do contraste. Após isso, as microcalcificações das imagens originais foram segmentadas utilizando o método da máxima entropia e algumas características foram extraídas, como contraste, entropia, homogeneidade, correlação e variância.

Com esse método, os resultados foram submetidos a classificação utilizando *random forest*, um algoritmo que utiliza árvores de decisão para identificar se um achado na mamografia é inexistente, benigno ou maligno. Também foi analisado o impacto de parâmetros, como o número de amostras e a quantidade de características a serem comparadas, na performance do sistema. A precisão total do sistema foi de 95%, com uma taxa de falso-positivos de 3% quando comparado com outros métodos classificatórios (FADIL *et al.*, 2020).

Observa-se que os trabalhos citados estabelecem uma etapa importante no processamento de imagens digitais: a segmentação de estruturas de interesse. No caso de imagens mamográficas, a segmentação é utilizada para auxiliar o diagnóstico, separando lesões e possibilitando a classificação automática. Portanto, deve-se analisar diferentes métodos de segmentação, como forma de facilitar a interpretação de resultados nos exames mamográficos.

6. MATERIAIS E MÉTODOS

6.1. Banco de Imagens

As imagens mamográficas utilizadas nesse trabalho são provenientes do banco de imagens INbreast no formato DICOM (*Digital Imaging and Communications in Medicine*). As imagens foram adquiridas no Centro Hospitalar de São João na cidade de Porto, Portugal entre abril de 2008 e julho de 2010. Para a aquisição, foi utilizado um mamógrafo digital FFDM (*Full Field Digital Mammography*) *MammoNovation* da fabricante *Siemens*, contendo um detector de selênio amorfo com resolução de 14 bits. As imagens variam de tamanho, entre 3328×4084 e 2560×3328 pixels, devido aos diferentes tamanhos de mama e compressão utilizados (MOREIRA et al., 2012).

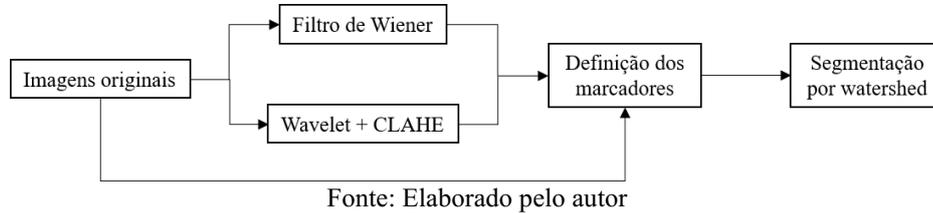
O padrão DICOM reúne diversas informações médicas acerca da paciente, entretanto, as imagens foram previamente anonimizadas, protegendo os dados das pacientes. O banco conta também com laudos realizados por radiologistas, facilitando a análise das imagens com informações como classificação BI-RADS (*Breast Imaging Reporting and Data System*), densidade mamária e existência de lesões (MOREIRA et al., 2012).

Para realizar a segmentação por *watershed*, foram selecionadas 52 imagens, presentes no banco de imagens INbreast, contendo nódulos e massas. Seguindo o padrão BI-RADS para densidade mamária, utilizou-se 21 imagens de mamas compostas inteiramente por tecido adiposo (padrão a); 19 imagens contendo tecido adiposo algumas áreas contendo tecido fibroglandular (padrão b); 9 imagens de mamas heterogeneamente densas, ou seja, composta majoritariamente por tecido fibroglandular (padrão c); e 3 imagens de mamas densas (padrão d) (SICKLES et al, 2013).

6.2. Processamento

Para o desenvolvimento do trabalho, foi desenvolvido um algoritmo em MATLAB (*MATrix LABoratory*) para o pré-processamento e segmentação das imagens originais. O processamento das imagens foi dividido em três etapas: primeiro, o pré-processamento para suavização do ruído e realce do contraste; segundo, a definição dos marcadores a serem utilizados como mínimos regionais na segmentação; e, por último, a segmentação utilizando *watershed*. A Figura 2 elucida as etapas desenvolvidas para o processamento das imagens.

Figura 2 - Etapas desenvolvidas para o processamento das imagens



Como primeiro passo, a imagem original foi segmentada para diminuir o fundo da imagem, minimizando a quantidade de pixels de intensidade 0. Após isso, o pré-processamento foi realizado de forma a resultar em duas imagens distintas: uma após a suavização com filtro de Wiener com máscara 3×3 e outra com *Wavelet* e CLAHE com máscara 15×15 para realce do contraste, seguindo os resultados indicados em Carneiro, 2019.

O tamanho da máscara do filtro de Wiener foi definido com base no trabalho de Oliveira, cujo objetivo era analisar a suavização do ruído em perfil de imagens mamográficas. Já para o processamento para realce do contraste, utilizou-se a metodologia proposta por Carneiro, na qual a imagem é processada pela transformada *Wavelet* e a CLAHE é aplicada apenas no coeficiente de aproximação da imagem (CARNEIRO, 2019; OLIVEIRA, 2019).

A transformada *wavelet* divide a imagem em quatro subimagens, quando aplicado um nível de decomposição, e é utilizada como método de suavização de ruído. Para isso, é necessária a aplicação de um *thresholding* nos coeficientes, o qual é definido utilizando a variância da imagem original e a distribuição Rayleigh. Durante a limiarização, os valores de intensidade abaixo do *thresholding* são transformados em valor igual a zero, realizando a suavização dos coeficientes. Além disso, é preciso definir a função base, ou *wavelet* mãe, para aplicação da transformada. A função *Coiflets5* foi escolhida como função base devido aos resultados obtidos por Costa Junior em seu trabalho com filtragem utilizando *wavelets* (CARNEIRO, 2019; COSTA JUNIOR, 2019).

O método para realce de contraste proposto por Carneiro aplica a técnica CLAHE, utilizando uma sub-região de tamanho 15×15 , apenas nos coeficientes de aproximação encontrados na transformada *wavelet*. Além disso, a CLAHE exige a definição de outros dois parâmetros, o limite de corte dos pixels e a função de distribuição, que nesse caso são 0.01 e distribuição uniforme. Após isso, é realizada a transformada inversa da *wavelet* com os

coeficientes de aproximação modificados e os coeficientes originais de correspondentes a diagonal, vertical e horizontal (CARNEIRO, 2019).

Para evitar a supersegmentação ao aplicar a segmentação por *watershed*, é necessário definir alguns marcadores, que selecionarão os mínimos regionais utilizados. Portanto, na segunda etapa, as três imagens (a imagem original, com a suavização de ruído com o filtro de Wiener e com o algoritmo de realce de contraste) passaram por um processamento com operações morfológicas. Como método, foi utilizado a abertura seguida pelo fechamento por reconstrução, objetivando minimizar a perda de informação e deformação das fronteiras dos objetos.

A fim de analisar o melhor formato e tamanho de elemento estruturante, decidiu-se pela utilização de dois formatos, *disk* e *diamond*, com os tamanhos de 25, 50 e 100 pixels. Os elementos estruturantes são máscaras binárias definidas com um formato e tamanho pré-definidos. Apenas pixels cuja vizinhança tenha características de intensidade semelhantes e se encaixe no tamanho do elemento estruturante aparecerão na imagem segmentada, ou seja, lesões menores que o tamanho definido não serão detectadas. Portanto, deve-se escolher cautelosamente para detectar os objetos e eliminar regiões irrelevantes simultaneamente.

Como o objetivo é detectar lesões, que geralmente são observadas com níveis de intensidade mais alto, utilizam-se os máximos regionais da imagem antes da detecção do fundo. Dessa forma, os pixels conectados com valores de intensidade constante, cercados por pixels de intensidade menor, são detectados. Isso permite definir as regiões de interesse que devem ser preservadas ao definir-se os marcadores (LEWIS, DONG, 2012).

Para suavizar as bordas dos máximos regionais detectados, utilizou-se algumas operações morfológicas com um elemento estruturante de tamanho 5x5 composto pelo valor escalar 1. Primeiramente, realizou-se o fechamento da imagem, com o objetivo de eliminar pequenos buracos no contorno do objeto. Após isso, fazer a erosão da imagem possibilita afinar as bordas, tornando a transição de intensidade entre a fronteira e o fundo menos abrupta.

Após isso, os marcadores podem ser encontrados pela divisão do fundo da imagem em diferentes regiões, preservando as regiões de máximos regionais detectadas. Dessa forma, é preciso estabelecer as regiões nas quais o método será utilizado através da aplicação da *watershed* na distância Euclidiana entre os pixels de uma imagem binária e o pixel com valor de intensidade 1 mais próximo. Com esse processamento, as linhas de *watershed* dividem a imagem de entrada em diferentes regiões tomando como base o fundo da imagem, reduzindo o

número de mínimos regionais total e objetivando detectar os objetos dentro dessas regiões (DOUGHERTY, 2009).

Por fim, com os marcadores definidos, inicia-se a terceira etapa com a segmentação por *watershed* aplicando-a ao gradiente da imagem. O gradiente da imagem é modificado seguindo os marcadores encontrados, de forma a forçar a segmentação apenas nas regiões definidas. Para facilitar a visualização do resultado, utiliza-se a dilatação, com um elemento estruturante de tamanho 5x5 composto pelo valor escalar 1, nas linhas de *watershed* detectadas. A Tabela 2 indica os processamentos realizados nas imagens, sendo que a primeira coluna estabelece os pré-processamentos utilizados na primeira etapa e a segunda coluna os tipos de elementos estruturantes utilizados na definição dos marcadores.

Tabela 2 - Processamentos realizados

Pré-processamento	Elemento estruturante
1) Imagem original	<i>Disk</i> tamanho 25
2) Filtro de Wiener	<i>Disk</i> tamanho 25
3) <i>Wavelet</i> + CLAHE	<i>Disk</i> tamanho 25
4) Imagem original	<i>Diamond</i> tamanho 25
5) Filtro de Wiener	<i>Diamond</i> tamanho 25
6) <i>Wavelet</i> + CLAHE	<i>Diamond</i> tamanho 25
7) Imagem original	<i>Disk</i> tamanho 50
8) Filtro de Wiener	<i>Disk</i> tamanho 50
9) <i>Wavelet</i> + CLAHE	<i>Disk</i> tamanho 50
10) Imagem original	<i>Diamond</i> tamanho 50
11) Filtro de Wiener	<i>Diamond</i> tamanho 50
12) <i>Wavelet</i> + CLAHE	<i>Diamond</i> tamanho 50
13) Imagem original	<i>Disk</i> tamanho 100
14) Filtro de Wiener	<i>Disk</i> tamanho 100
15) <i>Wavelet</i> + CLAHE	<i>Disk</i> tamanho 100
16) Imagem original	<i>Diamond</i> tamanho 100
17) Filtro de Wiener	<i>Diamond</i> tamanho 100
18) <i>Wavelet</i> + CLAHE	<i>Diamond</i> tamanho 100

Fonte: Elaborado pelo autor

Para avaliação das imagens, utilizou-se a curva ROC como forma de definir a efetividade o algoritmo de segmentação utilizado. A curva ROC utiliza o cálculo da sensibilidade e especificidade, ou seja, foi preciso comparar as regiões detectadas com a localização original das lesões e classificando-as nas categorias verdadeiro-positivo, verdadeiro-negativo, falso-positivo e falso-negativo. Nesse caso, a análise se deu da seguinte forma:

- Verdadeiro-positivo: imagens cujo resultado correspondem a uma região contendo uma lesão ou pelo menos uma das bordas da lesão é detectada quando ela realmente existe;
- Verdadeiro-negativo: ocorre quando o algoritmo não detecta nenhuma lesão e ela não existe na imagem;
- Falso-positivo: equivalente à detecção de regiões que não contém lesões e nenhuma lesão é detectada, sendo que ela existe na imagem original;
- Falso-negativo: referente à detecção da borda da mama ou à não detecção de nenhuma região da imagem, sendo que existe uma lesão na imagem.

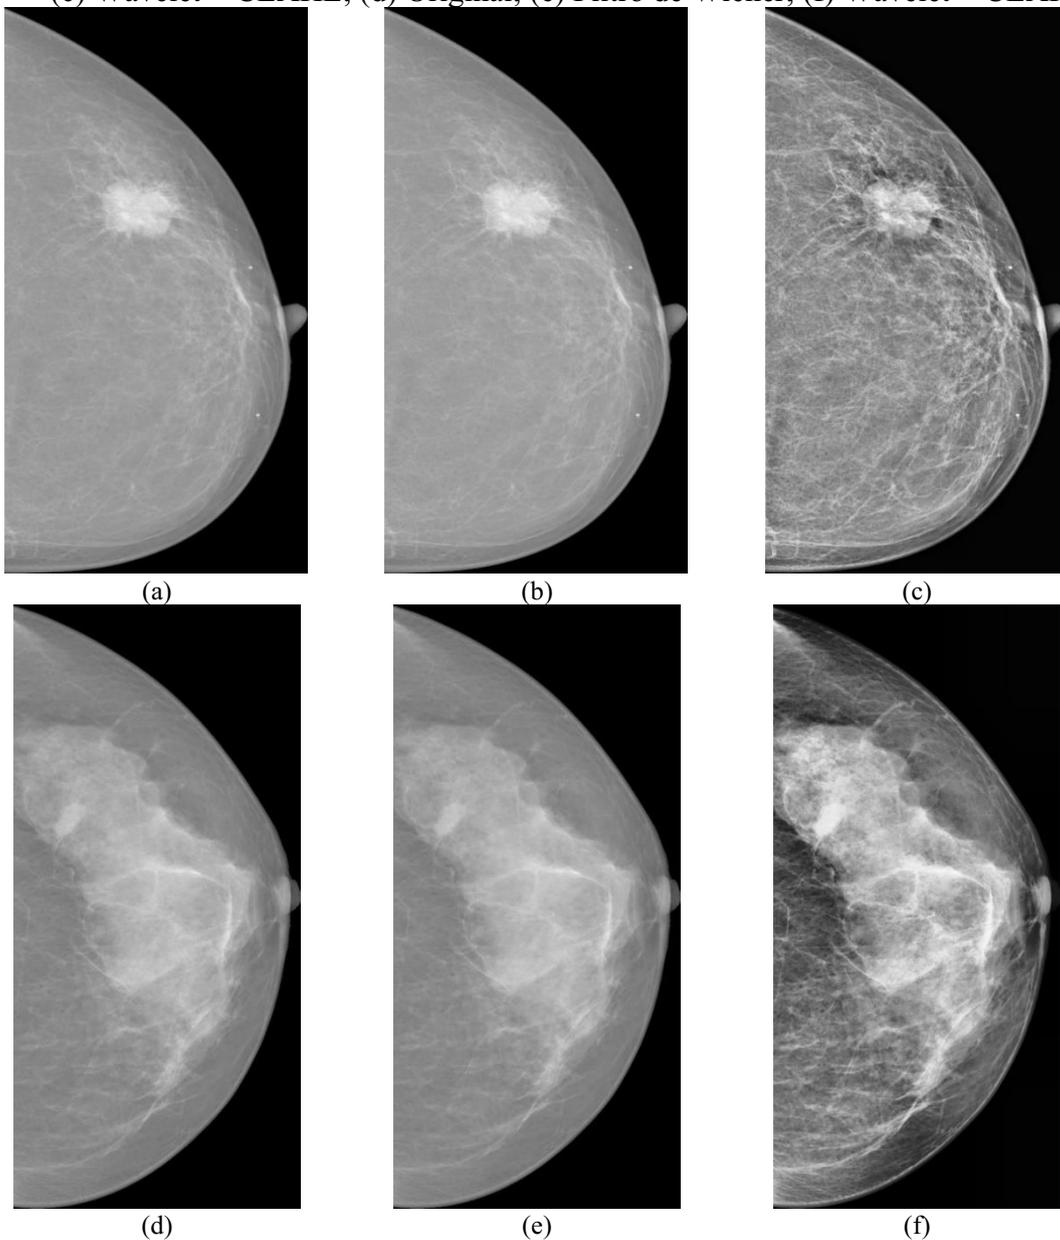
Com o objetivo de visualizar a curva ROC, foi utilizado o parâmetro sensibilidade no eixo das ordenadas e $1 -$ especificidade no eixo das abcissas. Além disso, o cálculo da área sob a curva permite analisar de forma quantitativa a eficiência do sistema e facilita a comparação entre curvas.

Também é necessário realizar a análise visual das imagens, para identificar as diferenças entre os processamentos utilizados. Essa análise é de extrema importância pois permite visualizar a variação na detecção das formas da lesão e da quantidade de regiões segmentadas.

7. RESULTADOS

Em um primeiro momento, com o pré-processamento das imagens originais, foram geradas 104 imagens pré-processadas com os algoritmos de suavização de ruído e realce de contraste. Portanto, ao todo, 156 imagens passaram pelo processo de definição dos marcadores. Como resultado, foram obtidas 936 imagens segmentadas utilizando a segmentação por *watershed*. A Figura 3 apresenta o resultado de algumas imagens após o pré-processamento, juntamente com a imagem original.

Figura 3 - Resultados do pré-processamento das imagens. (a) Original; (b) Filtro de Wiener; (c) Wavelet + CLAHE; (d) Original; (e) Filtro de Wiener; (f) Wavelet + CLAHE.



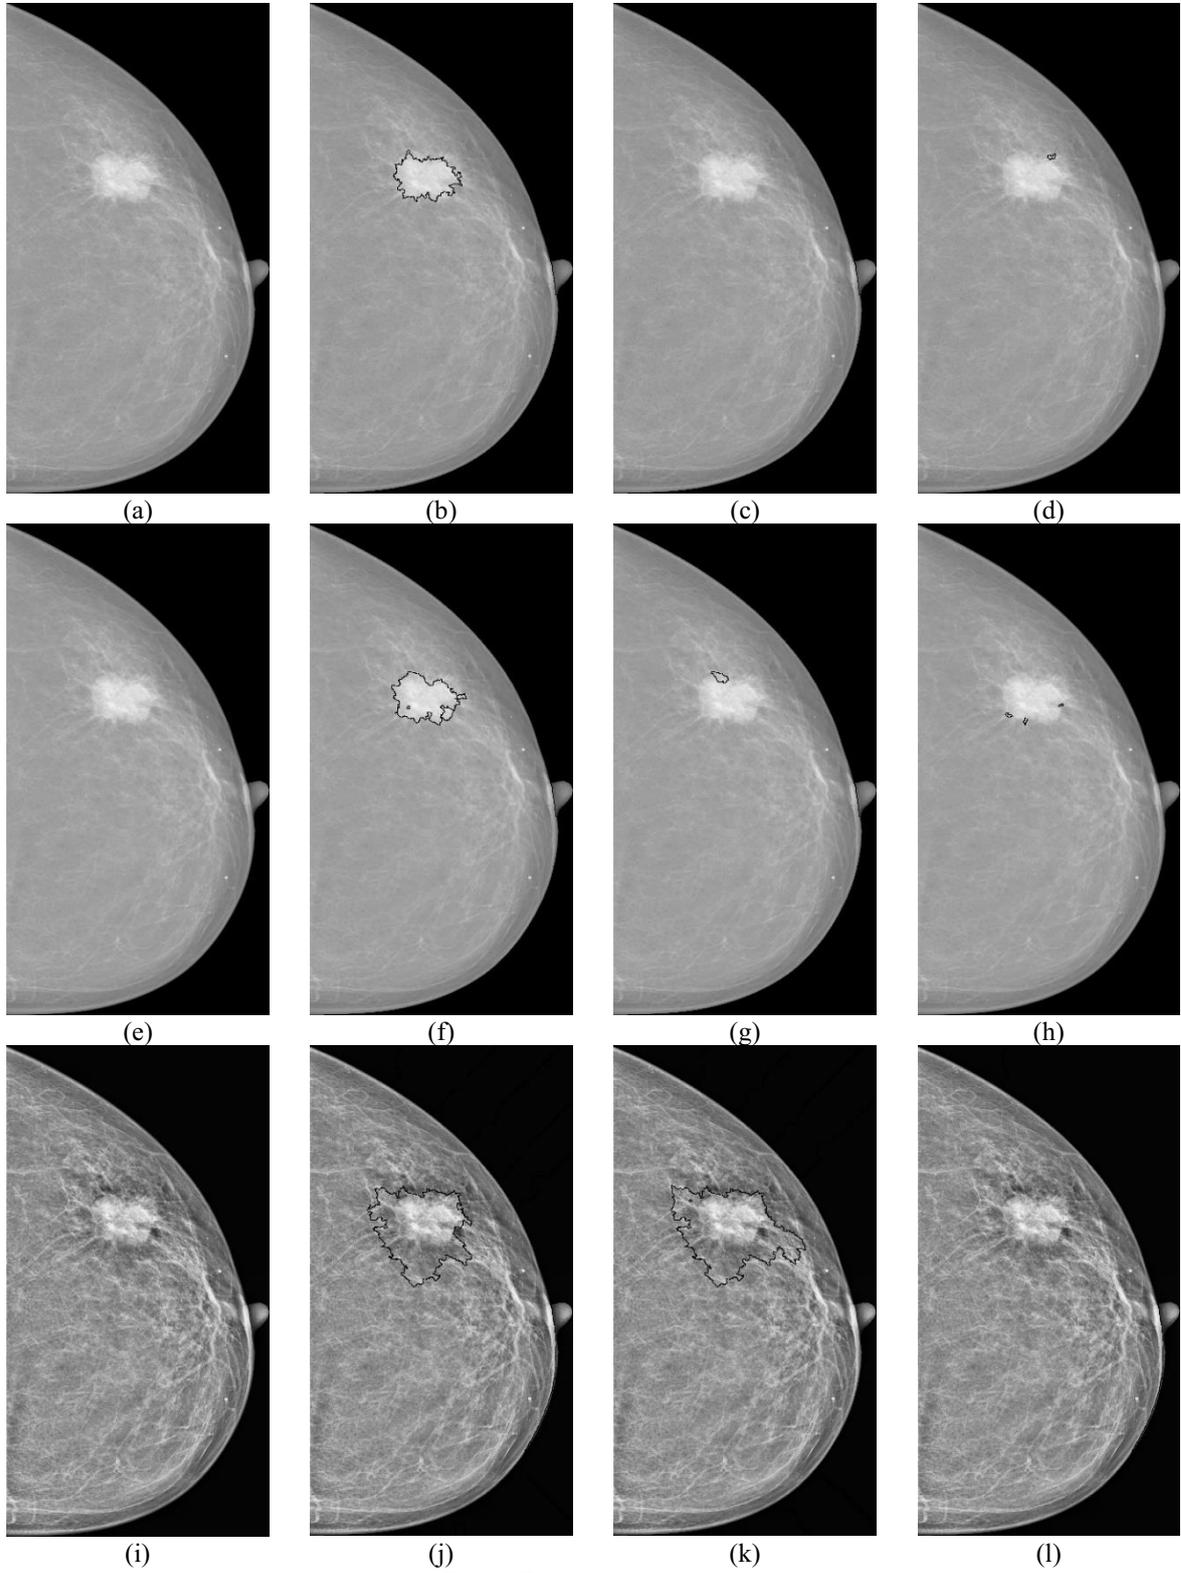
Fonte: Elaborado pelo autor

Visualmente, a não há mudança aparente entre a imagem original e a resultante da suavização de ruído. Entretanto, pode-se identificar relevante alteração através de métricas como o *Mean Square Error* – Erro Médio Quadrático (MSE) e o *Signal-to-Noise Ratio* – Relação Sinal-Ruído (SNR) (OLIVEIRA, 2019).

Já para o processamento de realce de contraste, é possível visualizar a alteração entre a imagem original e o resultado obtido. Esse passo é importante, principalmente em mamas densas, aumentando a diferença entre a intensidade dos pixels e permitindo visualizar mais facilmente as estruturas (CARNEIRO, 2019) Como o método CLAHE aplicado é considerado uma transformação de intensidade indireta, ocorre mudança no histograma da imagem, ou seja, apenas os valores de intensidade dos pixels são alterados (GONZALEZ, WOODS, 2010).

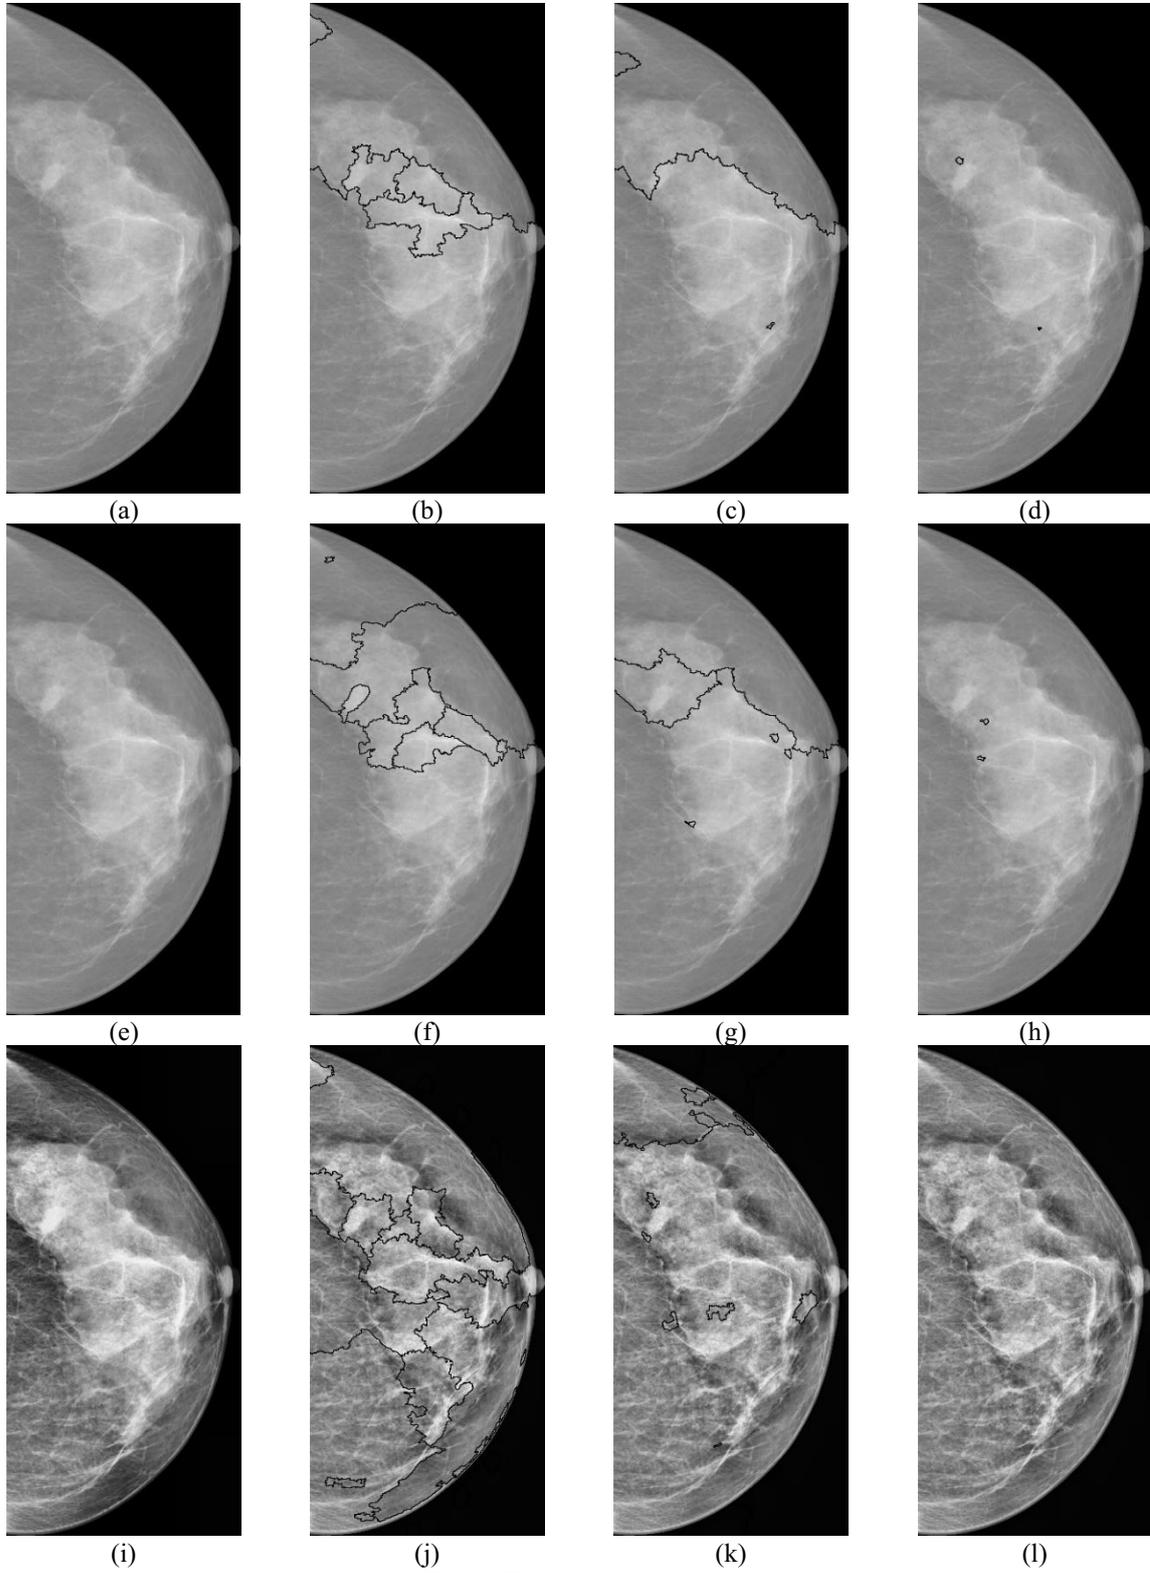
Após a segmentação, as linhas de *watershed* encontradas foram sobrepostas na imagem, de forma a facilitar a visualização dos resultados. A seguir, alguns exemplos de resultados encontrados. As Figuras 4 e 5 referem-se ao processamento com o elemento estruturante de formato *disk* enquanto as Figuras 6 e 7 exemplificam os resultados com o formato *diamond*.

Figura 4 - Resultado da segmentação por *watershed* com o formato *disk*. (a) Original; (b) Original + *disk* 25; (c) Original + *disk* 50; (d) Original + *disk* 100; (e) Wiener; (f) Wiener + *disk* 25; (g) Wiener + *disk* 50; (h) Wiener + *disk* 100; (i) Wavelet + CLAHE; (j) Wavelet + CLAHE + *disk* 25; (k) Wavelet + CLAHE + *disk* 50; (l) Wavelet + CLAHE + *disk* 100.



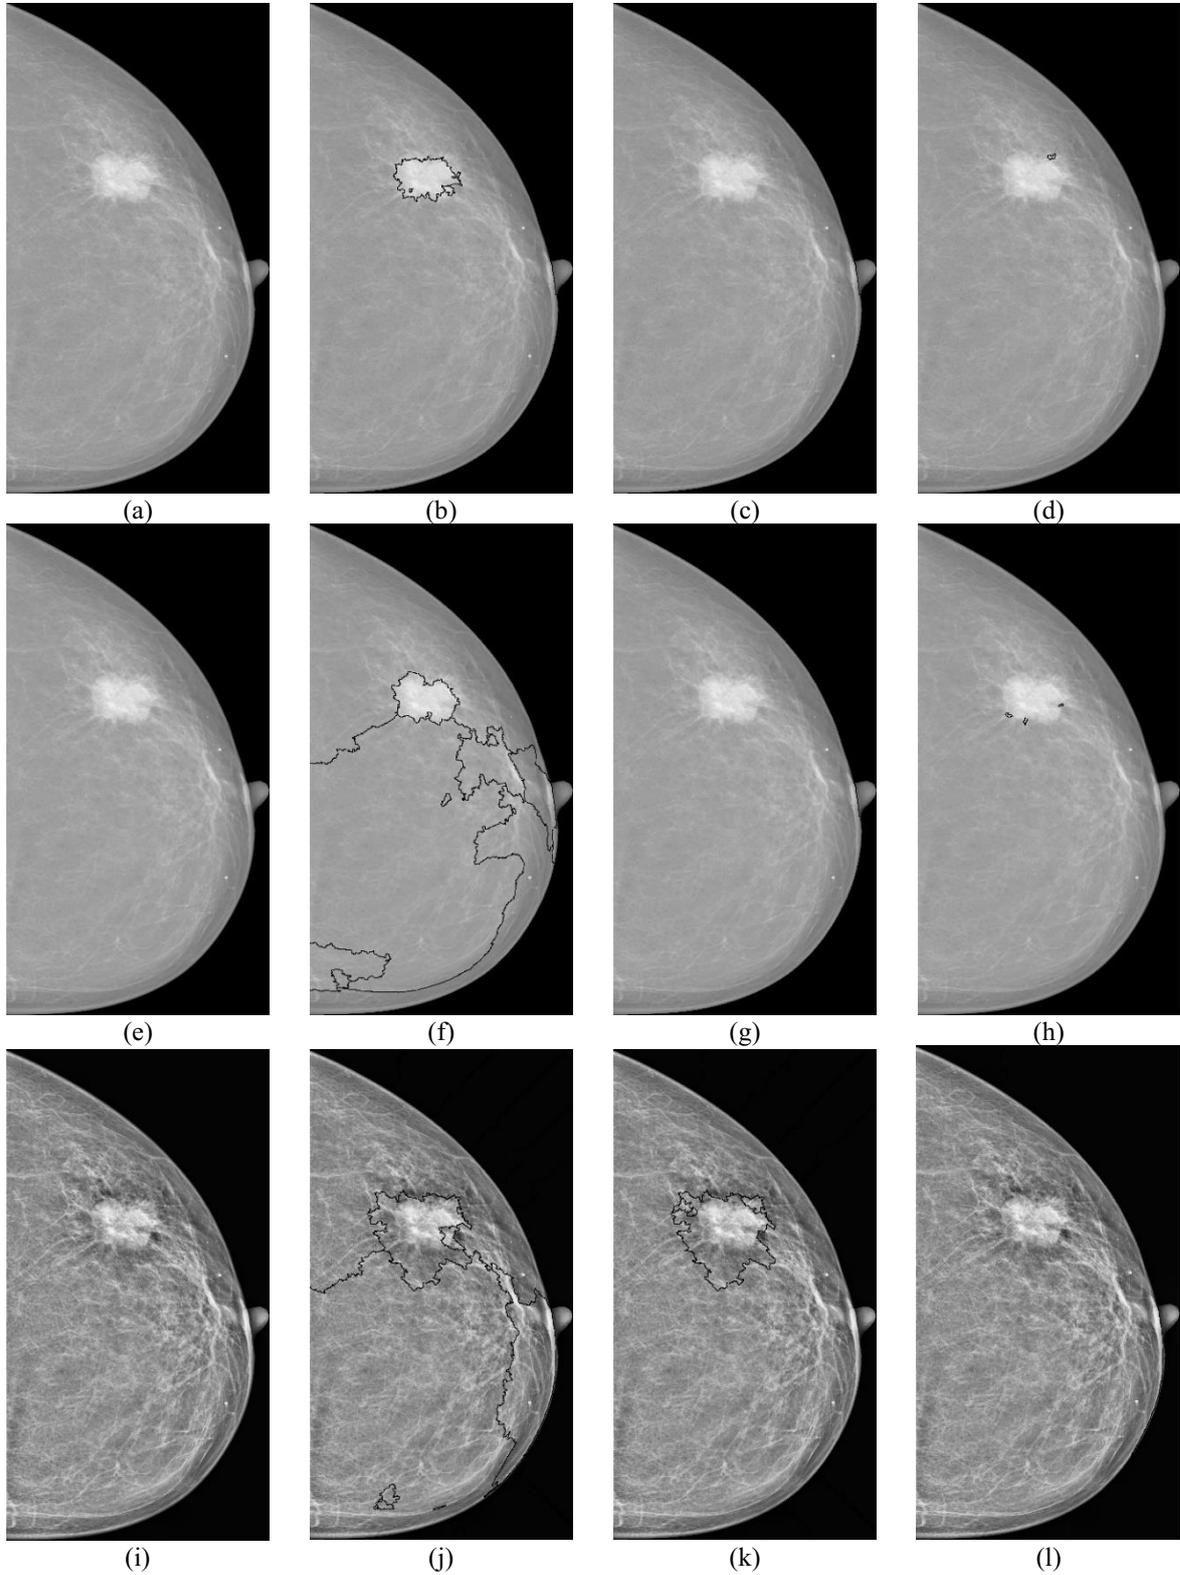
Fonte: Elaborado pelo autor

Figura 5 - Resultado da segmentação por *watershed* com o formato *disk*. (a) Original; (b) Original + *disk* 25; (c) Original + *disk* 50; (d) Original + *disk* 100; (e) Wiener; (f) Wiener + *disk* 25; (g) Wiener + *disk* 50; (h) Wiener + *disk* 100; (i) Wavelet + CLAHE; (j) Wavelet + CLAHE + *disk* 25; (k) Wavelet + CLAHE + *disk* 50; (l) Wavelet + CLAHE + *disk* 100.



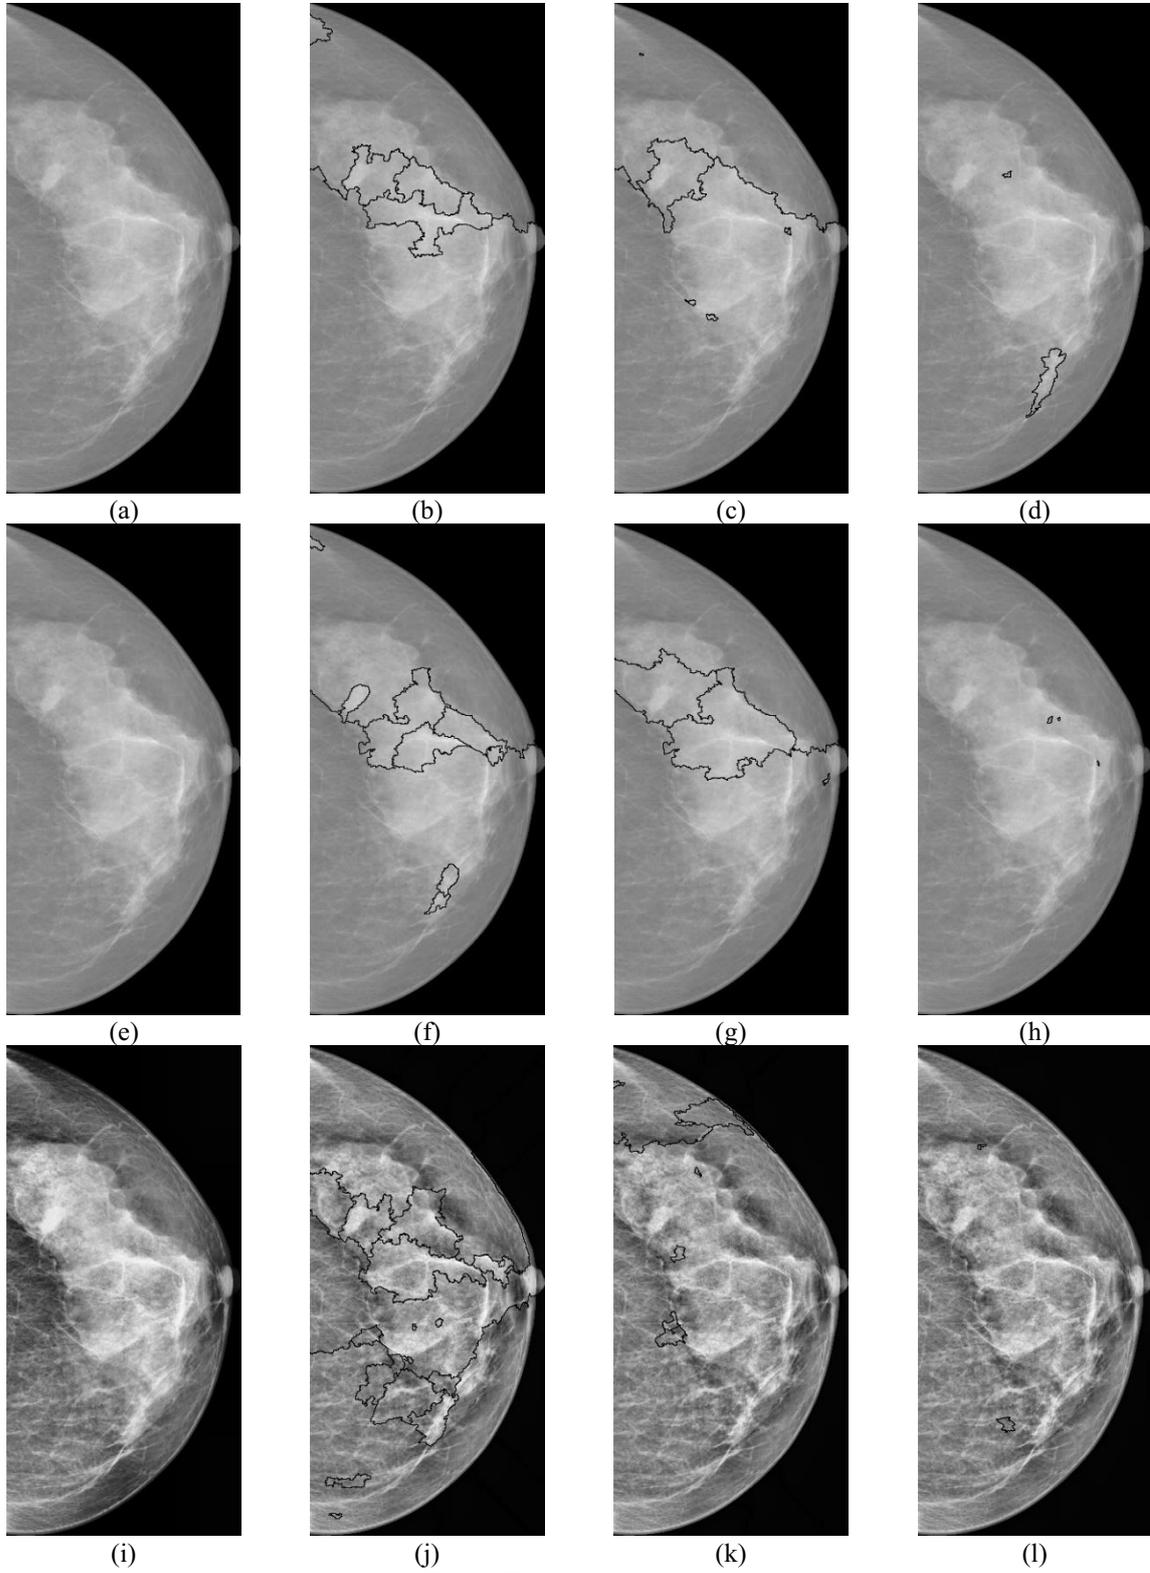
Fonte: Elaborado pelo autor.

Figura 6 - Resultado da segmentação por *watershed* com o formato *diamond*. (a) Original; (b) Original + *diamond* 25; (c) Original + *diamond* 50; (d) Original + *diamond* 100; (e) Wiener; (f) Wiener + *diamond* 25; (g) Wiener + *diamond* 50; (h) Wiener + *diamond* 100; (i) Wavelet + CLAHE; (j) Wavelet + CLAHE + *diamond* 25; (k) Wavelet + CLAHE + *diamond* 50; (l) Wavelet + CLAHE + *diamond* 100.



Fonte: Elaborado pelo autor.

Figura 7 - Resultado da segmentação por *watershed* com o formato *diamond*. (a) Original; (b) Original + *diamond* 25; (c) Original + *diamond* 50; (d) Original + *diamond* 100; (e) Wiener; (f) Wiener + *diamond* 25; (g) Wiener + *diamond* 50; (h) Wiener + *diamond* 100; (i) Wavelet + CLAHE; (j) Wavelet + CLAHE + *diamond* 25; (k) Wavelet + CLAHE + *diamond* 50; (l) Wavelet + CLAHE + *diamond* 100.



Fonte: Elaborado pelo autor.

A primeira análise a ser realizada é a comparação entre a quantidade de regiões detectadas com a variação do elemento estruturante na etapa de definição dos marcadores. A Tabela 3 indica o número médio de regiões detectadas para cada processamento realizado, permitindo a comparação entre os tamanhos, formatos e pré-processamentos utilizados.

Tabela 3 - Número médio de regiões segmentadas em cada processamento realizado

	Imagem original	Filtro de Wiener	Wavelet + CLAHE
Disk 25	14,52	21,94	41,48
Disk 50	6,35	8,33	21,19
Disk 100	6,08	7,79	9,90
Diamond 25	21,94	29,67	51,36
Diamond 50	7,00	7,85	17,23
Diamond 100	6,50	6,19	9,79

Fonte: Elaborado pelo autor.

Como esperado, o elemento estruturante identifica os pixels cuja vizinhança com características de intensidade semelhantes se encaixa perfeitamente no formato definido. Portanto, quanto menor o tamanho do elemento, mais pixels serão detectados. Analisando os valores médios calculados, observa-se que o tamanho 25 detectou mais regiões, tanto para o formato *disk* quanto para o *diamond*, independentemente do pré-processamento realizado na imagem. Visualmente, as Figuras 4, 5, 6 e 7 são um exemplo da diferença no número de regiões detectadas em cada segmentação.

Quanto à forma utilizada, os dois tipos obtiveram resultados semelhantes para os tamanhos 50 e 100. Entretanto, a maior diferença é observada no tamanho 25, em que o formato *diamond* detectou maior número de regiões. Isso significa que o elemento estruturante do tipo *diamond* conseguiu encontrar mais pixels cuja vizinhança se encaixava na máscara definida.

Outra observação é quanto a diferença entre o número de regiões detectadas entre os pré-processamentos utilizados. Sabe-se que o objetivo da suavização do ruído e realce do contraste é melhorar a qualidade da imagem, permitindo distinguir com mais facilidade as estruturas da imagem (DOUGHERTY, 2009). Isso fica claro pois mais regiões foram detectadas após o pré-processamento das imagens, destacando-se a quantidade observada no processamento com Wavelet e CLAHE.

A alteração do contraste da imagem permite identificar com maior clareza dois pontos adjacentes com níveis de intensidade diferentes. Ou seja, amplia-se a diferença de intensidade entre os pixels (DOUGHERTY, 2009; GONZALEZ, WOODS, 2010). Com esse aumento, o

elemento estruturante é capaz de identificar mais regiões com similaridade entre os pixels, aumentando o número total de regiões segmentadas.

Entretanto, observa-se que para o tamanho 100, nos dois formatos, não houve grande alteração no número médio de regiões detectadas com a mudança do pré-processamento. Isso ocorre devido ao maior número de falso-negativos quando se utiliza esse tipo de elemento estruturante, ou seja, não foi detectada nenhuma região ou apenas o contorno da mama. Esse fato também justifica a pouca variação entre os tamanhos 50 e 100, para as imagens originais e com filtro de Wiener. O baixo contraste impede que os elementos sejam distinguidos, dificultando a detecção pelos elementos estruturantes de maior tamanho e aumentando número de falso-negativos.

É importante ressaltar que apenas o número de regiões detectadas não é suficiente para identificar a eficiência do algoritmo de segmentação. Deve-se levar em consideração outras características como a forma, tamanho e densidade das regiões observadas. Como o objetivo é detectar apenas as regiões contendo lesões, o grande número de regiões segmentadas significa a supersegmentação da imagem. Esse problema deve ser minimizado com a melhoria do algoritmo de processamento para definição dos marcadores da imagem, que definem os mínimos regionais utilizados na segmentação por *watershed* (DOUGHERTY, 2009; GONZALEZ, WOODS, 2010; PANDEY, LALCHHANHIMA, 2020; SANTOS, 2002).

Como o elemento estruturante identifica apenas os pixels que contém a vizinhança similar com o tamanho definido, as regiões segmentadas com elementos do tamanho 100 são muito menores quando comparadas aos outros resultados. Ou seja, o algoritmo encontrou regiões muito pequenas cujos pixels possuem as mesmas características de intensidade estabelecidas no raio de 100 pixels. Essa relação pode ser verificada visualmente nos exemplos das Figuras 4 e 5.

Para a análise da performance do algoritmo de segmentação, foi preciso avaliar individualmente cada um dos resultados, observando visualmente a área segmentada e as condições de classificação. Desse modo, cada imagem foi identificada como verdadeiro-positivo, falso-positivo e falso-negativo. Nenhuma das imagens foi classificada como verdadeiro-negativo, pois não foram utilizadas imagens sem lesões nesse trabalho.

Com o número de resultados em cada classificação, foi possível calcular matematicamente algumas métricas, como a acurácia e a curva ROC. A acurácia utiliza o número de verdadeiro-positivos observado, ou seja, permite avaliar a porcentagem de imagens

segmentadas corretamente. Já a curva ROC, utiliza os resultados verdadeiros-positivos e falso-positivos, fornecendo informações acerca da eficiência do sistema, através da área sob a curva.

A Tabela 4 demonstra os resultados obtidos após avaliação das imagens, sendo VP o número de verdadeiro-positivos; VN o número de verdadeiro-negativos; FP o número de falso-positivos; e FN o número de falso-negativos.

Tabela 4 - Resultados encontrados após a segmentação das imagens

	VP	FP	FN	Acurácia
1) Imagem original + <i>disk</i> 25	71,15%	23,08%	5,77%	71,15%
2) Filtro de Wiener + <i>disk</i> 25	86,54%	13,46%	0,00%	86,54%
3) Wavelet + CLAHE + <i>disk</i> 25	71,15%	28,85%	0,00%	71,15%
4) Imagem original + <i>diamond</i> 25	76,92%	21,15%	1,92%	76,92%
5) Filtro de Wiener + <i>diamond</i> 25	88,46%	9,62%	1,92%	88,46%
6) Wavelet + CLAHE + <i>diamond</i> 25	80,77%	19,23%	0,00%	80,77%
7) Imagem original + <i>disk</i> 50	19,23%	53,85%	27,56%	19,23%
8) Filtro de Wiener + <i>disk</i> 50	28,85%	51,92%	19,23%	28,85%
9) Wavelet + CLAHE + <i>disk</i> 50	13,46%	69,23%	17,31%	13,46%
10) Imagem original + <i>diamond</i> 50	26,92%	50,00%	23,08%	26,92%
11) Filtro de Wiener + <i>diamond</i> 50	53,85%	32,69%	13,46%	53,85%
12) Wavelet + CLAHE + <i>diamond</i> 50	26,92%	61,54%	11,54%	26,92%
13) Imagem original + <i>disk</i> 100	5,77%	71,15%	23,08%	5,77%
14) Filtro de Wiener + <i>disk</i> 100	5,77%	75,00%	19,23%	5,77%
15) Wavelet + CLAHE + <i>disk</i> 100	0,00%	46,15%	53,85%	0,00%
16) Imagem original + <i>diamond</i> 100	5,77%	69,23%	25,00%	5,77%
17) Filtro de Wiener + <i>diamond</i> 100	11,54%	65,40%	23,06%	11,54%
18) Wavelet + CLAHE + <i>diamond</i> 100	1,92%	57,69%	40,39%	1,92%

Fonte: Elaborado pelo autor.

Através da Tabela 4, pode-se perceber que os processamentos com maior acurácia foram os que utilizaram tamanho 25 para os elementos estruturantes. Observou-se que os valores de acurácia são maiores que 70%, tornando-os consideravelmente maiores que os resultados com outros tamanhos. Isso ocorre pois o quanto menor o tamanho, menos criterioso será o algoritmo, portanto, mais regiões serão segmentadas. É importante ressaltar que, conseguindo identificar as regiões com lesões, esses processamentos sofrem com supersegmentação.

Portanto, é preciso realizar melhorias na definição dos marcadores, para que as regiões irrelevantes sejam eliminadas, utilizando outros parâmetros na segmentação, como forma, tamanho e nível de cinza.

Já quanto ao formato de elemento estruturante, observou-se que o formato *diamond* foi mais eficiente na maioria dos casos, quando considerando os mesmos tamanhos e pré-processamentos. A diferença é expressiva em alguns casos, chegando a 25% (filtro de Wiener, tamanho 50). Porém, é preciso avaliar visualmente a relação entre a forma das regiões segmentadas e o formato de elemento estruturante utilizado, a fim de verificar se os formatos foram capazes de identificar ou não os mesmos casos da mesma maneira.

Observando apenas a variação de pré-processamento, as segmentações realizadas em imagens com o filtro de Wiener obtiveram maiores acurácias. Isso ocorre, pois, a existência de ruído interfere na qualidade de detecção de regiões, devido as variações de intensidade. As imagens processadas após a aplicação de Wavelet e CLAHE obtiveram melhor resultado que as segmentações com imagens originais, porém, não foram tão eficientes quanto os processamentos sem realce de contraste. A equalização do histograma realizado pela CLAHE modifica as intensidades dos pixels, alterando a visualização das estruturas. Porém, em alguns casos, são detectadas muitas regiões sem relevância que impedem a segmentação apropriada das lesões.

No contexto geral, pode-se notar que o processamento com maior número de verdadeiro-positivos foi a combinação do filtro de Wiener com o elemento estruturante *diamond* tamanho 25 pixels. Esse processamento obteve 88,46% de acurácia, pouco a mais que o formato *disk* de mesmo tamanho, que apresentou 86,54%. Isso indica que a redução de ruído e a utilização de elementos estruturantes menores são mais eficientes na segmentação de estruturas de interesse.

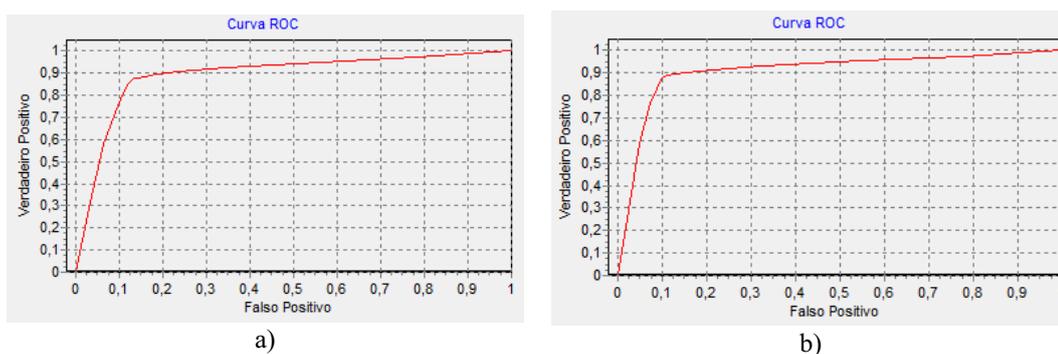
Além disso, analisando a taxa verdadeiro-positivos para cada densidade de mama, podemos ressaltar o impacto do pré-processamento na segmentação quando analisado o perfil de densidade mamária das imagens. Por exemplo, as lesões presentes nas imagens do padrão d, mamas densas, só foram detectadas após a redução do ruído e realce do contraste, sendo que a segmentação realizada nas imagens processadas com Wavelet e CLAHE apresentaram melhor detecção de forma. Para o padrão c, mamas heterogeneamente densas, o processamento com Wavelet e CLAHE foi mais efetivo, apresentando maior número de verdadeiro-positivos quando comparado com o filtro de Wiener.

Isso indica que para a segmentação de imagens com densidade mamária padrões c e d, é necessário realizar o pré-processamento e melhorar a visualização das estruturas. Portanto, o algoritmo de definição dos marcadores deve ser aprimorado para identificar corretamente as lesões após a alteração do contraste. Outra questão é a quantidade de imagens analisadas desse padrão foi pequena, sendo importante a análise de uma amostra maior para validação dos resultados.

Para análise da performance do sistema, a curva ROC foi utilizada nos casos com acurácia maior que 50%. Os casos com acurácia menor que 50% apresentaram muitos falso-negativos, o que prejudica a análise de eficiência. A curva ROC utiliza o cálculo da sensibilidade e $1 -$ especificidade para identificar os acertos na detecção da lesão (verdadeiros-positivos) e os erros (falsos-positivos). Quanto mais próximo o gráfico for do canto superior esquerdo, mais eficiente o sistema, devido a maior área sob a curva (RIBEIRO, 2016; SANTOS 2002).

A Figura 8 apresenta duas curvas obtidas pelos processamentos realizados. Quanto mais próximo do canto superior esquerdo o gráfico estiver, maior a eficiência do processamento. Nesse caso, os dois melhores processamentos foram comparados, a fim de investigar a melhoria de performance com a mudança do formato do elemento estruturante.

Figura 8 - Exemplos de curvas ROC geradas para análise da performance do sistema. a) Filtro de Wiener + *disk* 25 b) Filtro de Wiener + *diamond* 25



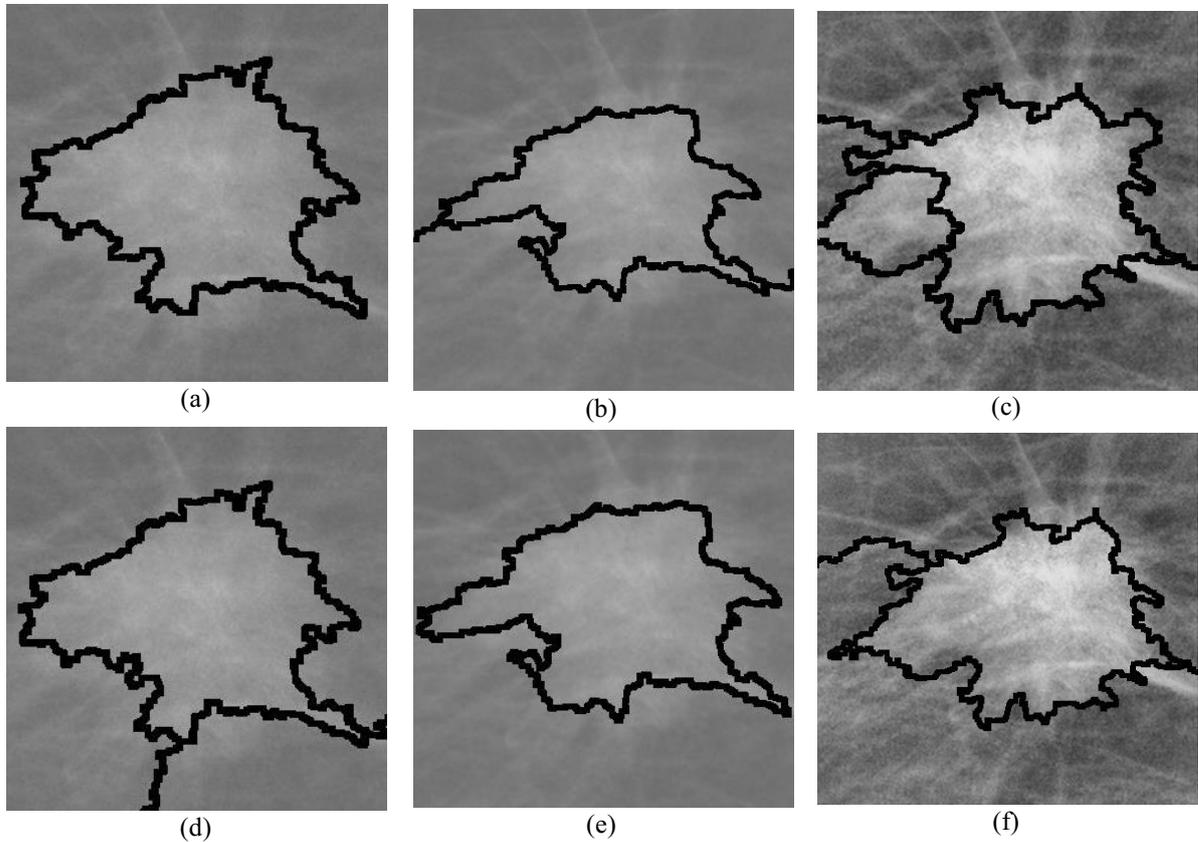
Fonte: Elaborado pelo autor.

Com o cálculo da área sob a curva ROC (AUC), é possível comparar de maneira mais fácil a eficiência de cada processamento na detecção de regiões contendo lesões. Os valores calculados estão entre 0 e 1, portanto, quanto mais próximo de 1, maior a performance do processamento (RIBEIRO, 2016; SANTOS 2002). Para o caso da Figura 8, o formato *disk*

obteve AUC igual a 0,891, enquanto o formato *diamond* tem 0,909, ou seja, o tipo *diamond* demonstrou ser mais eficiente.

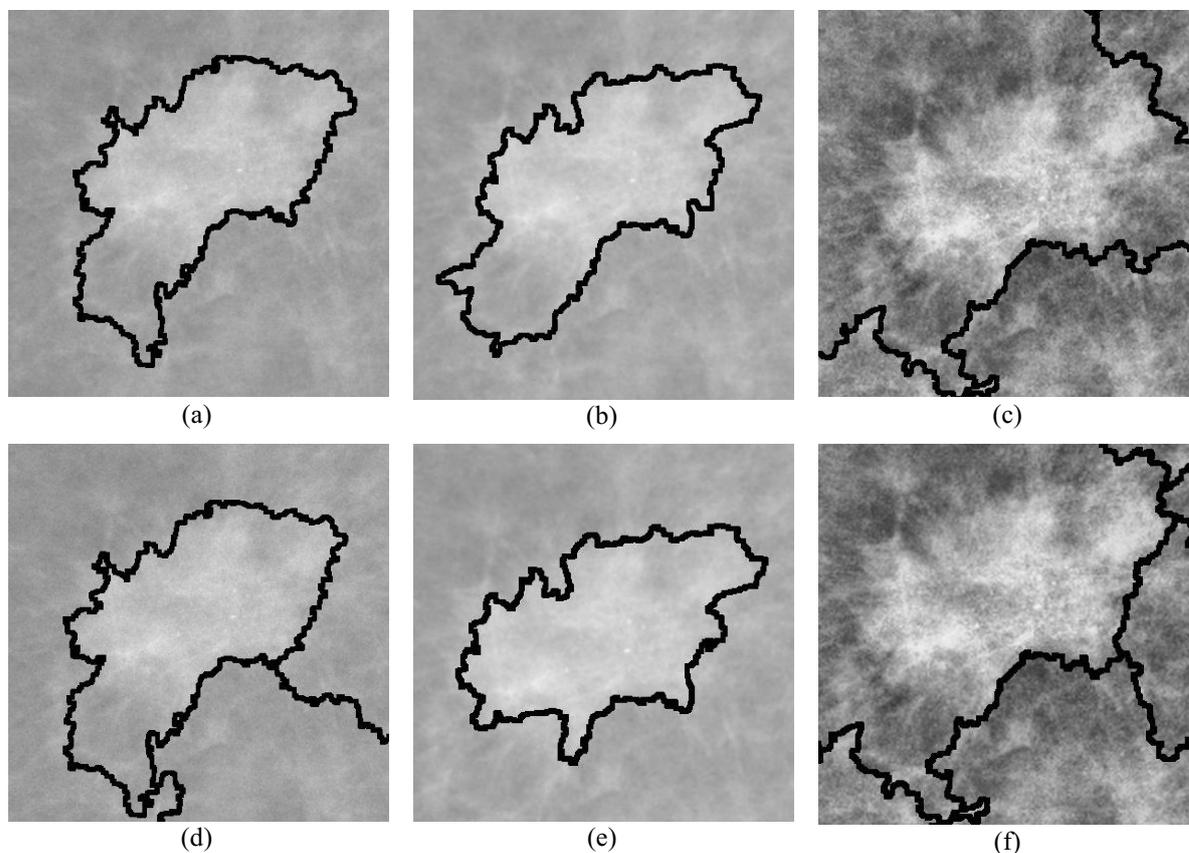
Quanto à forma das regiões segmentadas, observou-se resultados variados quando comparados com o mesmo tamanho e pré-processamento. Essa diferença está atrelada ao formato do nódulo, o que dificulta a padronização de um elemento estruturante ideal para aplicações em segmentação por *watershed*. As Figura 10 e 11 exemplificam a forma detectada de uma mesma região para os diversos processamentos.

Figura 10 - Exemplos de diferenças entre as formas da lesão detectada. (a) Imagem original + *disk* 25; (b) Wiener + *disk* 25; (c) Wavelet + CLAHE + *disk* 25; (d) Imagem original + *diamond* 25; (e) Wiener + *diamond* 25; (f) Wavelet + CLAHE + *diamond* 25.



Fonte: Elaborado pelo autor.

Figura 11 - Exemplos de diferenças entre as formas da lesão detectada. (a) Imagem original + *disk* 25; (b) Wiener + *disk* 25; (c) Wavelet + CLAHE + *disk* 25; (d) Imagem original + *diamond* 25; (e) Wiener + *diamond* 25; (f) Wavelet + CLAHE + *diamond* 25.



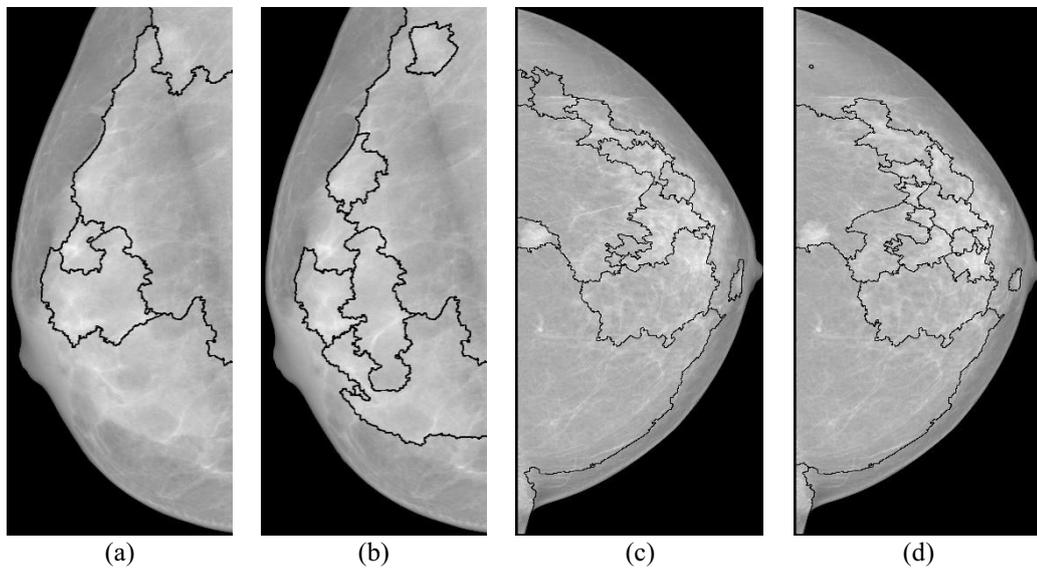
Fonte: Elaborado pelo autor.

Com o exemplo da Figuras 10, pode-se analisar a alteração provocada pelo pré-processamento na forma do nódulo segmentado. É possível observar que não há distinção relevante entre as formas detectadas nas imagens originais e com suavização do ruído. Entretanto, a característica irregular da borda dos nódulos presentes nas imagens é mais evidenciada após o realce de contraste utilizando *wavelet* e CLAHE, como mostrado nas imagens (c) e (f). Infelizmente, nesse caso, nenhum dos processamentos teve êxito em segmentar as espículas do nódulo.

Já na Figura 11, observa-se que não há diferença expressiva nos processamentos que utilizaram a imagem original, exemplificados nas imagens (a) e (d). Entretanto, após a aplicação do filtro de Wiener, imagens (b) e (e), as formas detectadas pelo algoritmo foram distintas, sendo que o formato *diamond* foi mais preciso na detecção da borda. Por fim, pode-se verificar que após o realce do contraste, imagens (c) e (f), o sistema detectou apenas uma das bordas do nódulo, sendo incapaz de segmentar a área de interesse corretamente.

Outra questão observada, foi que, em alguns casos, uma lesão foi detectada utilizando um formato de elemento estruturante e passou despercebida utilizando outro. Um exemplo é a Figura 12, em que as imagens (a) e (c) correspondem a segmentação utilizando o formato *disk* enquanto as imagens (b) e (d) ao formato *diamond*, todos de tamanho 25 e aplicados após a suavização do ruído com o filtro de Wiener. Observa-se que as imagens processadas com o formato *diamond* não contém a segmentação da estrutura de interesse, além de possuir maior número de regiões encontradas.

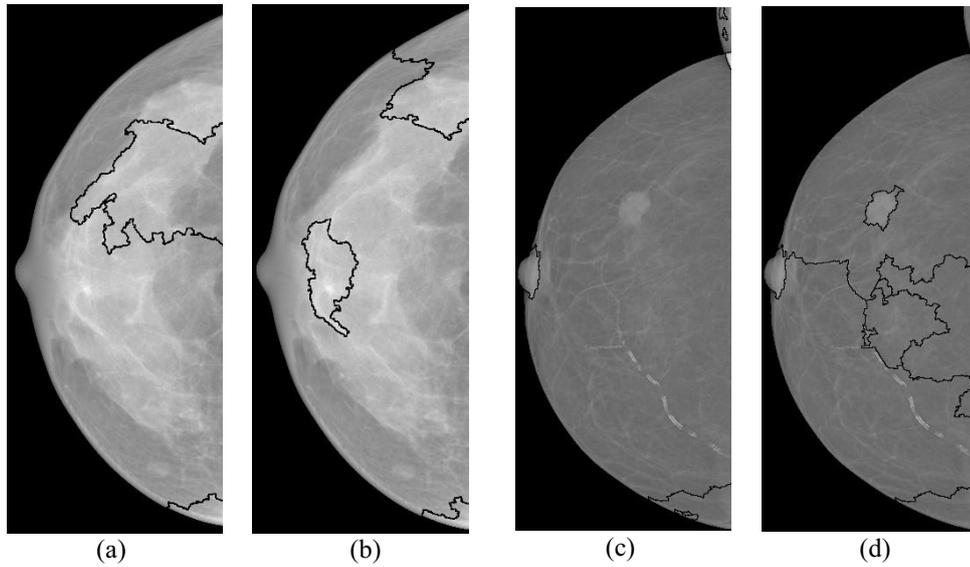
Figura 12 - Imagens segmentadas após a filtragem com o filtro de Wiener. (a) Wiener + *disk* 25; (b) Wiener + *diamond* 25; (c) Wiener + *disk* 25; (d) Wiener + *diamond* 25.



Fonte: Elaborado pelo autor.

Entretanto, como demonstrado na Figura 13, também foram encontrados casos em que o inverso foi observado. Nesse exemplo, o formato *disk*, utilizado nas imagens (a) e (d), não foi capaz de detectar a região que contém a lesão da mama. Já o formato *diamond*, cujo resultado corresponde as imagens (c) e (d) segmentou a região, mesmo que não perfeitamente.

Figura 13 - Imagens segmentadas após a filtragem com o filtro de Wiener. (a) Wiener + *disk* 25; (b) Wiener + *diamond* 25; (c) Wiener + *disk* 25; (d) Wiener + *diamond* 25.



Fonte: Elaborado pelo autor.

Os exemplos elucidados nas Figuras 12 e 13 demonstram a complexidade do processo de segmentação de imagens mamográficas. Muitas variáveis podem alterar o resultado, como a densidade da mama e o formato, tipo e tamanho da lesão presente na imagem (PANDEY, LALCHHANHIMA, 2020; GOCERI, 2019; SANTOS, 2002).

8. CONCLUSÃO

A segmentação de imagens mamográficas tem importante papel no auxílio ao diagnóstico de câncer de mama. Detectar digitalmente lesões mamárias facilita a visualização pelo radiologista, além de ser fundamental nos algoritmos de classificação automática. Analisando a técnica de segmentação por *watershed*, observa-se que alguns parâmetros afetam diretamente o resultado, como o pré-processamento da imagem e o elemento estruturante utilizado na definição dos marcadores.

Através da mudança do pré-processamento, verificou-se que após a suavização do ruído e realce do contraste, o algoritmo tem mais facilidade em detectar lesões mamárias. Isso ocorre como esperado, já que o objetivo do pré-processamento é melhorar a visualização e análise das imagens, tanto pelo radiologista quanto por sistemas computacionais. Podemos ressaltar a eficiência do sistema na detecção de lesões em mamas densas, a qual aumenta após o realce do contraste.

Quanto a variação dos elementos estruturantes utilizados, foi possível constatar a relação entre tamanho da máscara e quantidade de regiões segmentadas. Como relatado na literatura, quanto maior o elemento estruturante, menor o número de contornos detectados. Os casos que fogem a regra são resultado do número de falso-negativos verificados nos processamentos. Também é possível estabelecer uma relação entre o tamanho do elemento estruturante e o tamanho da região detectada, já que quanto maior a máscara, menor a região, devido ao número de pixels que obedecem às regras estabelecidas pelas operações morfológicas.

Com a mudança no formato do elemento estruturante, conclui-se que o formato *diamond* é capaz de detectar mais regiões, sendo elas de interesse ou não. Isso ocorre durante a definição dos marcadores, processamento no qual a máscara analisa a vizinhança de um pixel conforme suas similaridades de intensidade da região. Entretanto, é importante ressaltar que a detecção de muitas regiões pode significar a supersegmentação da imagem. Esse problema pode ser atenuado através da melhoria do algoritmo de definição dos marcadores.

Com o cálculo da acurácia, observou-se que a segmentação utilizando elementos estruturantes de tamanho 25 pixels foi mais efetiva, mesmo com maior presença de supersegmentação. Além disso, os melhores resultados foram obtidos com as imagens processadas apenas com filtro de Wiener, indicando que a redução de ruído é um fator muito importante na segmentação de lesões mamárias.

Além disso, a curva ROC e o cálculo da área sob a curva permitiu avaliar a performance do processamento, levando em consideração o número de resultados verdadeiro-positivos e falso-positivos. A partir disso, foi possível comprovar a importância do pré-processamento da imagem mamográfica e o potencial dos elementos estruturantes de menor tamanho na definição dos marcadores.

Por fim, observou-se que, nos casos em que foram detectadas lesões, o algoritmo não foi capaz de detectar perfeitamente o contorno das lesões mamárias em todas as imagens. Isso ocorre devido a variação da densidade mamária, forma, tamanho e tipo das lesões mamárias. Portanto, é preciso concluir o diagnóstico através da análise visual pelo radiologista, o que ressalta o caráter auxiliar dos sistemas computacionais desenvolvidos para imagens mamográficas.

Em trabalhos futuros é possível expandir a análise para outros pré-processamentos de suavização de ruído e realce de contraste, visando obter a melhor relação entre a filtragem e a segmentação. Além disso, o algoritmo de definição dos marcadores pode ser melhorado através de outras técnicas de processamento digital de imagens, de forma aumentar a efetividade da segmentação por *watershed* e aplicação em sistemas classificadores.

9. REFERÊNCIAS

- AL-ANTARI, Mugahed A. et al. A fully integrated computer-aided diagnosis system for digital X-ray mammograms via deep learning detection, segmentation, and classification. **International Journal of Medical Informatics**, v. 117, p. 44-54, 2018.
- BANKMAN, Isaac H. **Handbook of medical image processing and analysis**. Elsevier, 2009.
- BRAGA, A. C. D. S. **Curvas ROC: aspectos funcionais e aplicações**, 2000, 267 f. Dissertação (Doutorado em Métodos Numéricos e Estatísticos) - Universidade do Minho, Braga, 2000.
- BRASIL. Ministério da Saúde; Instituto Nacional do Câncer. **Mamografia: da prática ao controle**. Rio de Janeiro: INCA, 2007. Disponível em: <https://www.inca.gov.br/publicacoes/livros/mamografia-da-pratica-ao-controle>. Acesso em: 26 de abril de 2021.
- BUSHBERG, Jerrold T. et al. **The essential physics of medical imaging**. Lippincott Williams & Wilkins, 2011.
- CARNEIRO, P. C. et al. CLAHE Parameters Effects on the Quantitative and Visual Assessment of Dense Breast Mammograms. **IEEE Latin America Transactions**, v. 17, n.5, p. 851-857, 2019. Disponível em: <https://doi.org/10.1109/TLA.2019.8891954>.
- CARNEIRO, Pedro Cunha. **Proposta de metodologia para realce de contraste em imagens de mamas densas utilizando decomposição multiescala com transformada discreta wavelet**. 2019. 210 f. Tese (Doutorado em Engenharia Elétrica) - Universidade Federal de Uberlândia, Uberlândia, 2019. Disponível em: <https://doi.org/10.14393/ufu.te.2019.2593>.
- COSTA JÚNIOR, Carlos Alberto. **Proposta de uma metodologia para suavização de ruído em imagens mamográficas de mamas densas**. 2019. 78 f. Dissertação (Mestrado em Engenharia Biomédica) - Universidade Federal de Uberlândia, Uberlândia, 2019. Disponível em: <http://dx.doi.org/10.14393/ufu.di.2019.2036>.
- DOUGHERTY, Geoff. **Digital image processing for medical applications**. Cambridge University Press, 2009.
- EMBONG, Rohana; ANUAR; Siti R. Structuring Elements in the Watershed Algorithm for the Segmentation of Mammography Images. **TENCON 2018 - 2018 IEEE Region 10 Conference**, p. 2144-2147, 2018. Disponível em: <https://doi.org/10.1109/TENCON.2018.8650121>.
- FADIL, R. et al. Classification of Microcalcifications in Mammograms using 2D Discrete Wavelet Transform and Random Forest. **2020 IEEE International Conference on Electro Information Technology (EIT)**, p. 353-359, 2020. Disponível em: <https://doi.org/10.1109/EIT48999.2020.9208290>.
- GONZALEZ, WOODS, Rafael C.; WOODS, Richard C. **Processamento digital de imagens**. Pearson Educación, 2010.

GOCERI, Evgin. Challenges and Recent Solutions for Image Segmentation in the Era of Deep Learning. **2019 Ninth International Conference on Image Processing Theory, Tools and Applications (IPTA)**, p. 1-6, 2019. Disponível em: <https://doi.org/10.1109/IPTA.2019.8936087>.

INCA. Instituto Nacional do Câncer José de Alencar Gomes da Silva. 2021. Disponível em: <https://www.inca.gov.br/tipos-de-cancer/cancer-de-mama>. Acesso em: 26 de abril de 2021.

INCA. Instituto Nacional do Câncer José de Alencar Gomes da Silva. 2021. Disponível em: <https://www.inca.gov.br/numeros-de-cancer>. Acesso em: 26 de abril de 2021.

LEWIS, S. H.; DONG, A. Detection of breast tumor candidates using marker-controlled watershed segmentation and morphological analysis. **2012 IEEE Southwest Symposium on Image Analysis and Interpretation**, p. 1-4, 2012. Disponível em: <https://doi.org/10.1109/SSIAI.2012.6202438>.

OLIVEIRA, Mariane Modesto. **Avaliação de ruído em perfil de imagens mamográficas**. 2019. 57 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Biomédica) – Universidade Federal de Uberlândia, Uberlândia, 2019.

MOREIRA, I. C. et al. INbreast: toward a full-field digital mammographic database. **Academic Radiology**, v. 19, n. 2, p. 236-248, 2012. <https://doi.org/10.1016/j.acra.2011.09.014>.

MANDA, M. P et al. Marker-based watershed algorithm for segmentation of the infrared images. **2019 International SoC Design Conference (ISOCC)**, p. 227-228, 2019. Disponível em: <https://doi.org/10.1109/ISOCC47750.2019.9027721>.

PARK, S. H.; GOO, J. M.; JO, C.-H. Receiver operating characteristic (ROC) curve: practical review for radiologists. **Korean Journal of Radiology**, v. 5, n. March, p. 11–8, 2004.

PANDEY, Rahul; LALCHHANHIMA, R. Segmentation Techniques for Complex Image: Review. **2020 International Conference on Computational Performance Evaluation (ComPE)**, p. 804-808, 2020. Disponível em: <https://doi.org/10.1109/ComPE49325.2020.9200027>.

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

RIBEIRO, Rodolfo dos Santos. **Desenvolvimento de uma ferramenta para treinamento em leituras de mamografias digitais**. 2016. 103 f. Dissertação (Mestrado em Ciências) - Universidade Federal de Uberlândia, Uberlândia, 2016. Disponível em: <https://doi.org/10.14393/ufu.di.2016.566>.

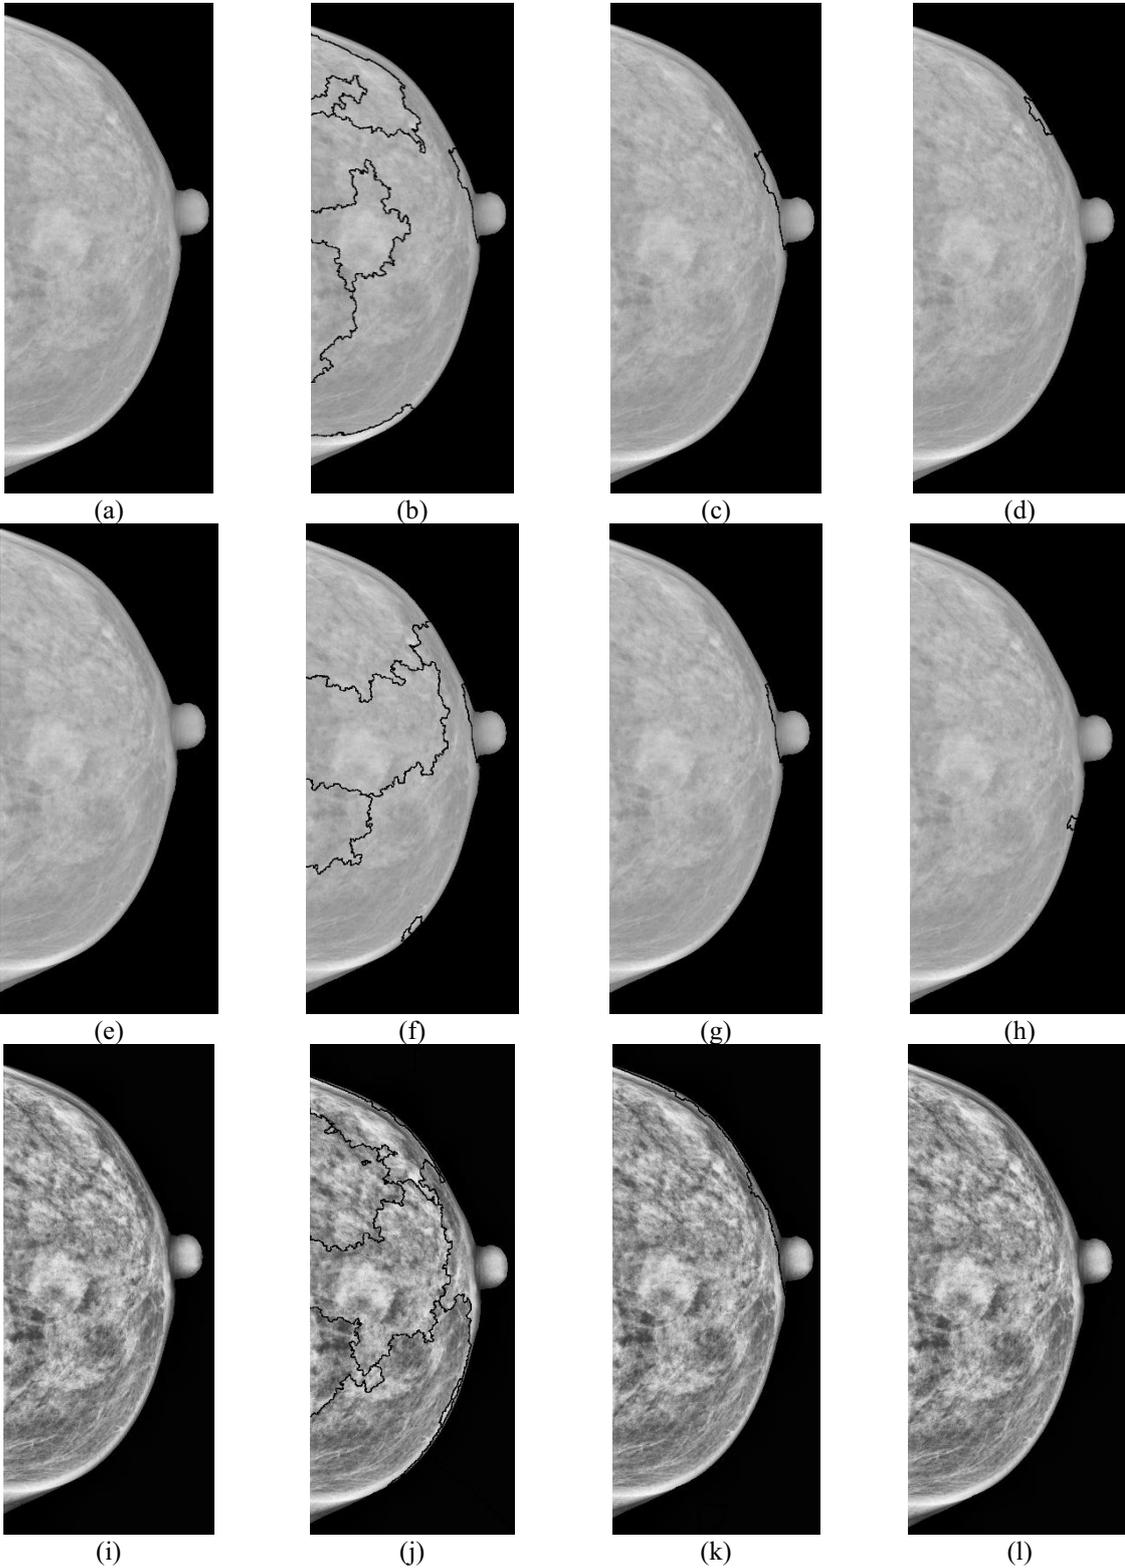
SANTOS, Vivian Toledo. **Segmentação de imagens mamográficas para detecção de nódulos em mamas densas**. 2002. Dissertação (Mestrado em Engenharia Elétrica) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2002. <http://doi.org/10.11606/D.18.2002.tde-16042003-183808>

SICKLES, E. A. et al. **ACR BI-RADS® Mammography**. In: ACR BI-RADS® Atlas, Breast Imaging Reporting and Data System. Reston, VA, American College of Radiology; 2013.

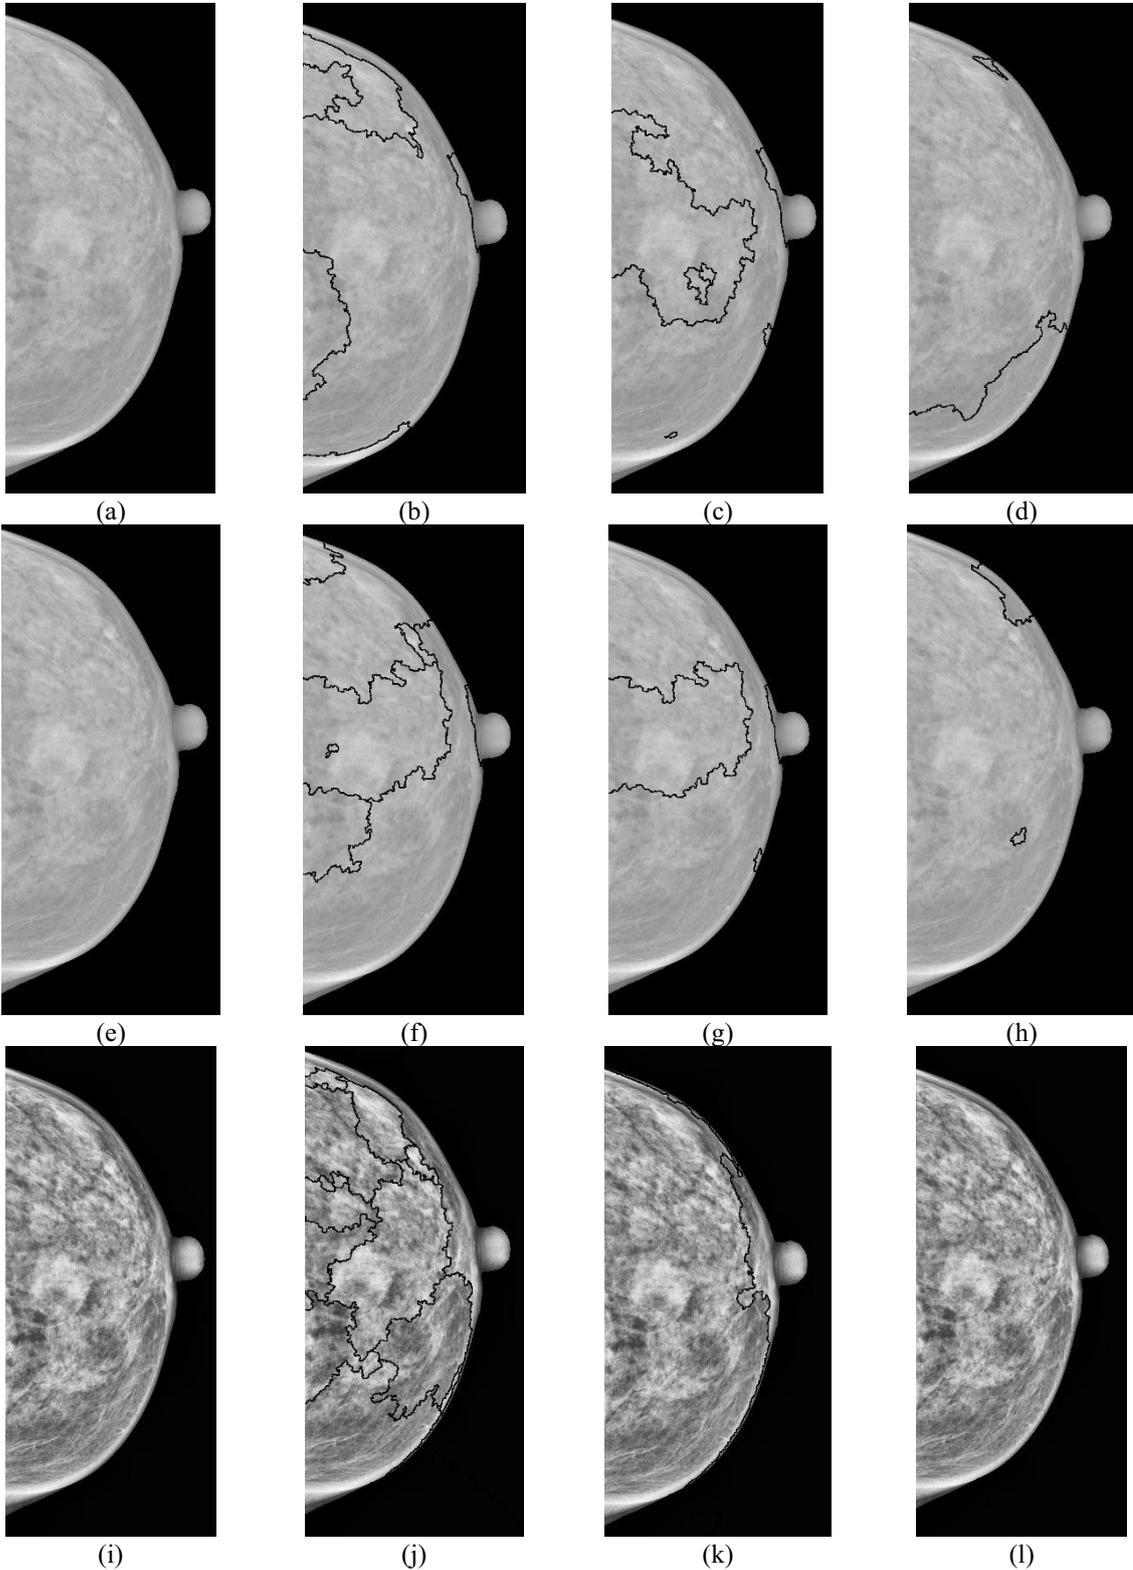
WORD HEALTH ORGANIZATION. International Agency for Research on Cancer, 2021. Disponível em: <https://www.iarc.who.int/pressrelease/world-cancer-day-breast-cancer-overtakes-lung-cancer-as-leading-cause-of-cancer-worldwide>. Acesso em 26 de abril de 2021.

APÊNDICE A – Imagens segmentadas

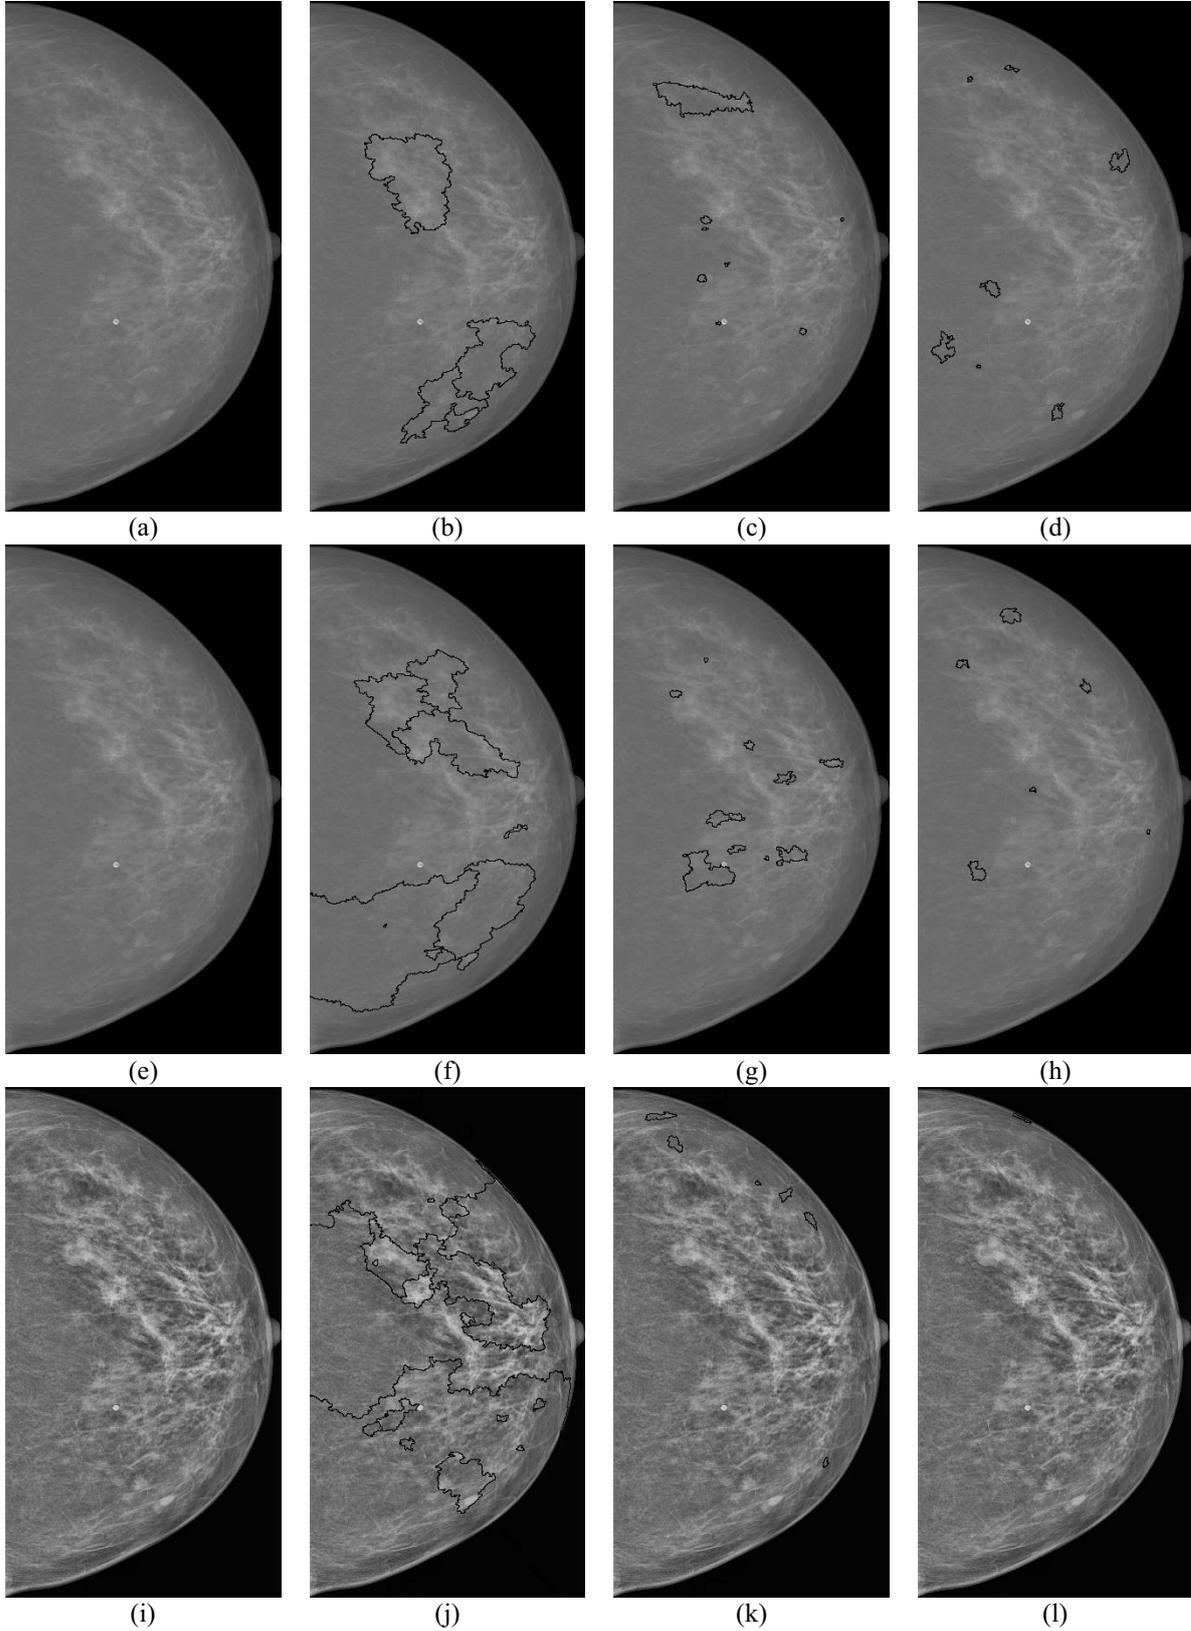
Resultado da segmentação por *watershed* com o formato *disk*. (a) Original; (b) Original + *disk* 25; (c) Original + *disk* 50; (d) Original + *disk* 100; (e) Wiener; (f) Wiener + *disk* 25; (g) Wiener + *disk* 50; (h) Wiener + *disk* 100; (i) Wavelet + CLAHE; (j) Wavelet + CLAHE + *disk* 25; (k) Wavelet + CLAHE + *disk* 50; (l) Wavelet + CLAHE + *disk* 100.



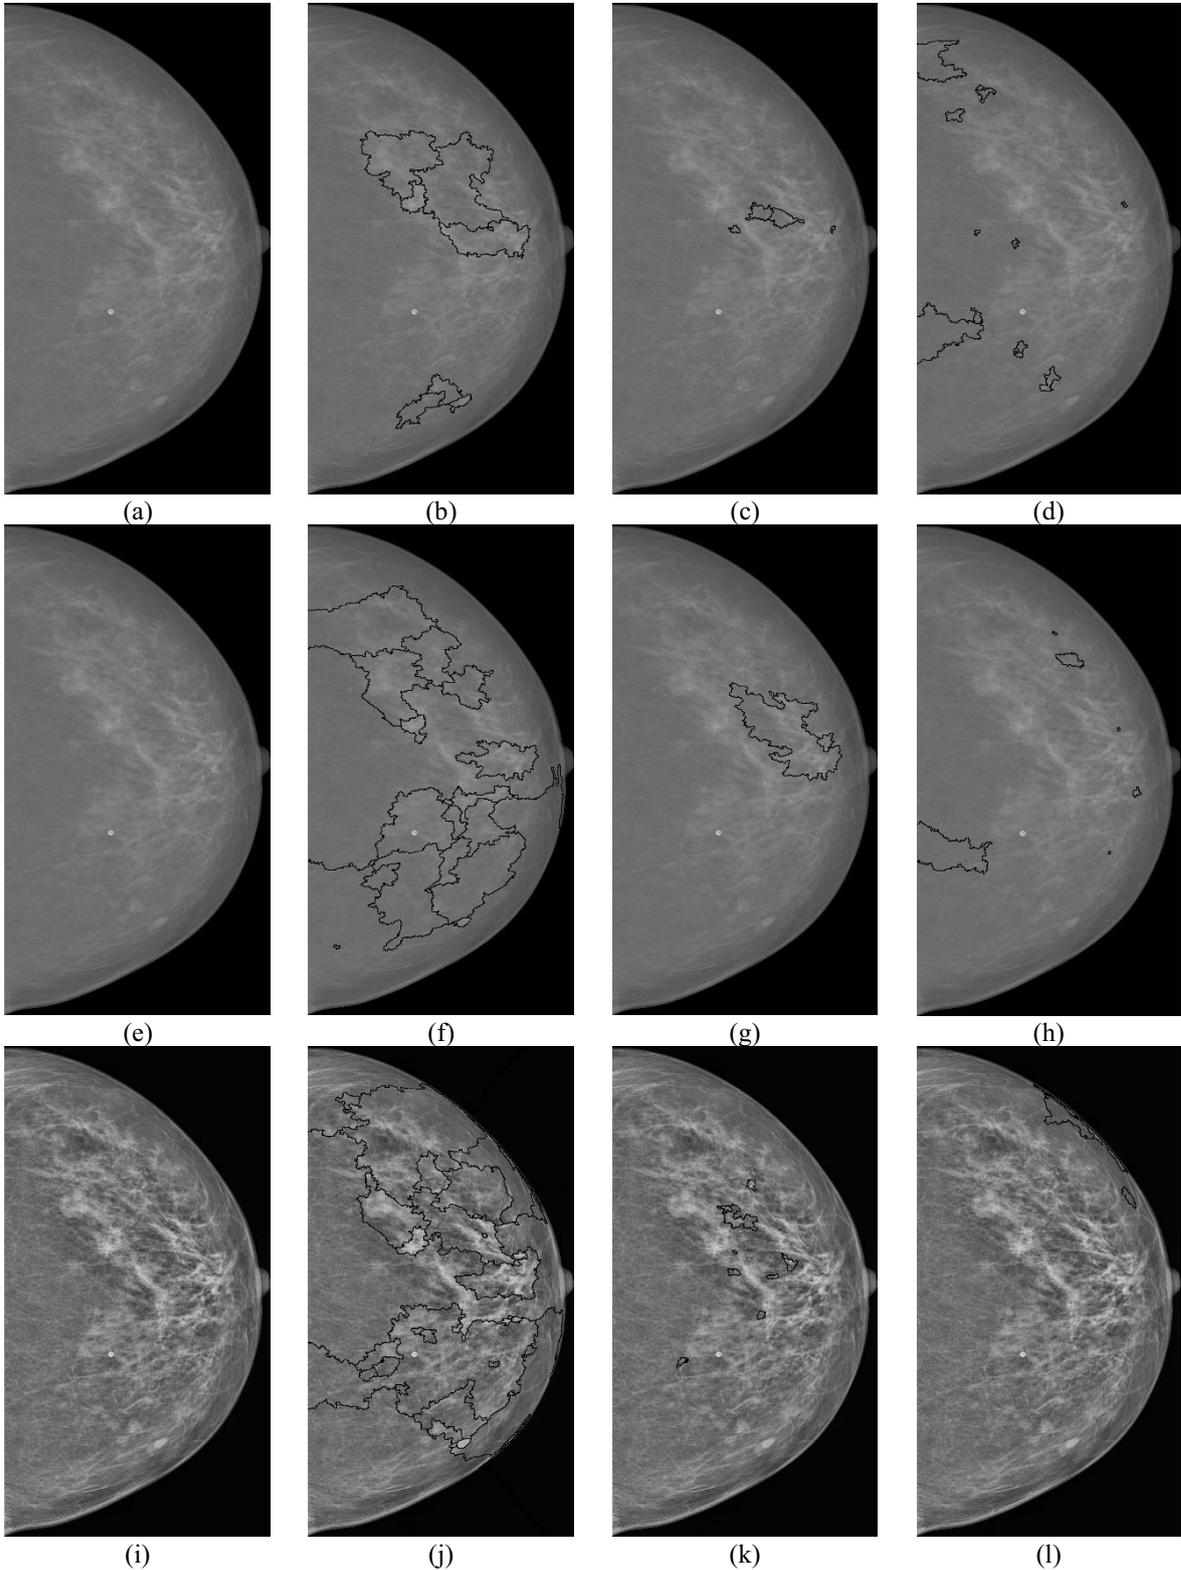
Resultado da segmentação por *watershed* com o formato *diamond*. (a) Original; (b) Original + *diamond* 25; (c) Original + *diamond* 50; (d) Original + *diamond* 100; (e) Wiener; (f) Wiener + *diamond* 25; (g) Wiener + *diamond* 50; (h) Wiener + *diamond* 100; (i) Wavelet + CLAHE; (j) Wavelet + CLAHE + *diamond* 25; (k) Wavelet + CLAHE + *diamond* 50; (l) Wavelet + CLAHE + *diamond* 100.



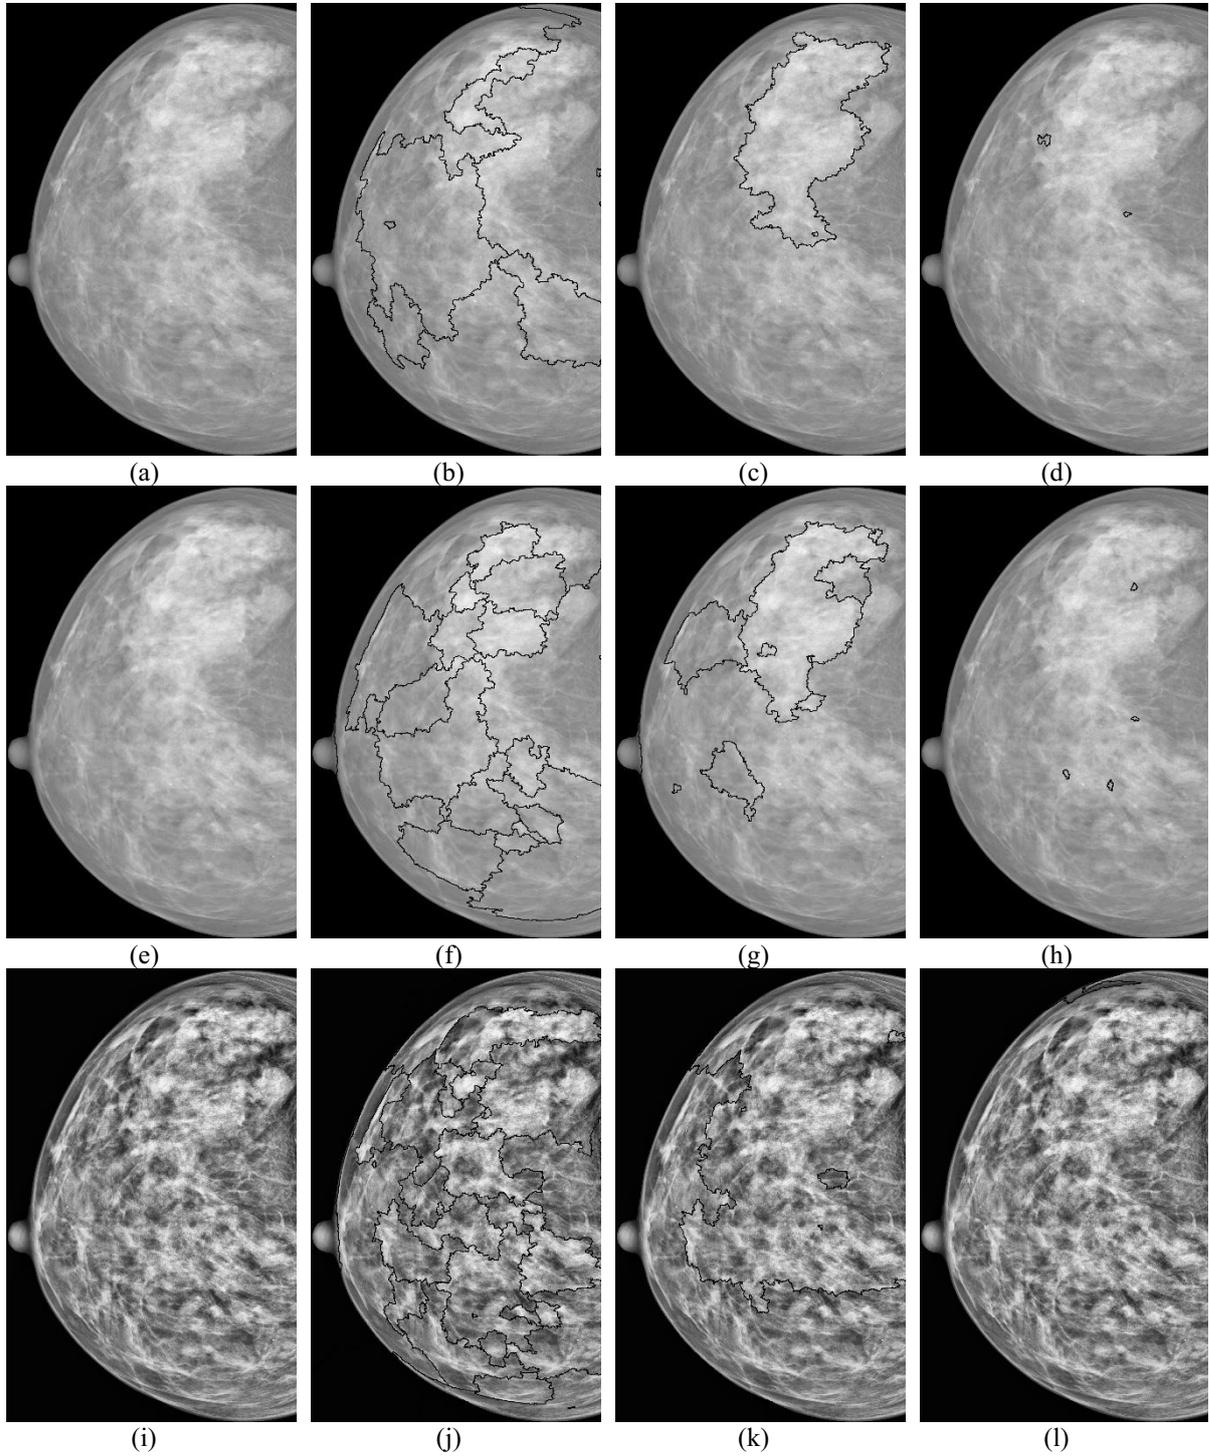
Resultado da segmentação por *watershed* com o formato *disk*. (a) Original; (b) Original + *disk* 25; (c) Original + *disk* 50; (d) Original + *disk* 100; (e) Wiener; (f) Wiener + *disk* 25; (g) Wiener + *disk* 50; (h) Wiener + *disk* 100; (i) Wavelet + CLAHE; (j) Wavelet + CLAHE + *disk* 25; (k) Wavelet + CLAHE + *disk* 50; (l) Wavelet + CLAHE + *disk* 100.



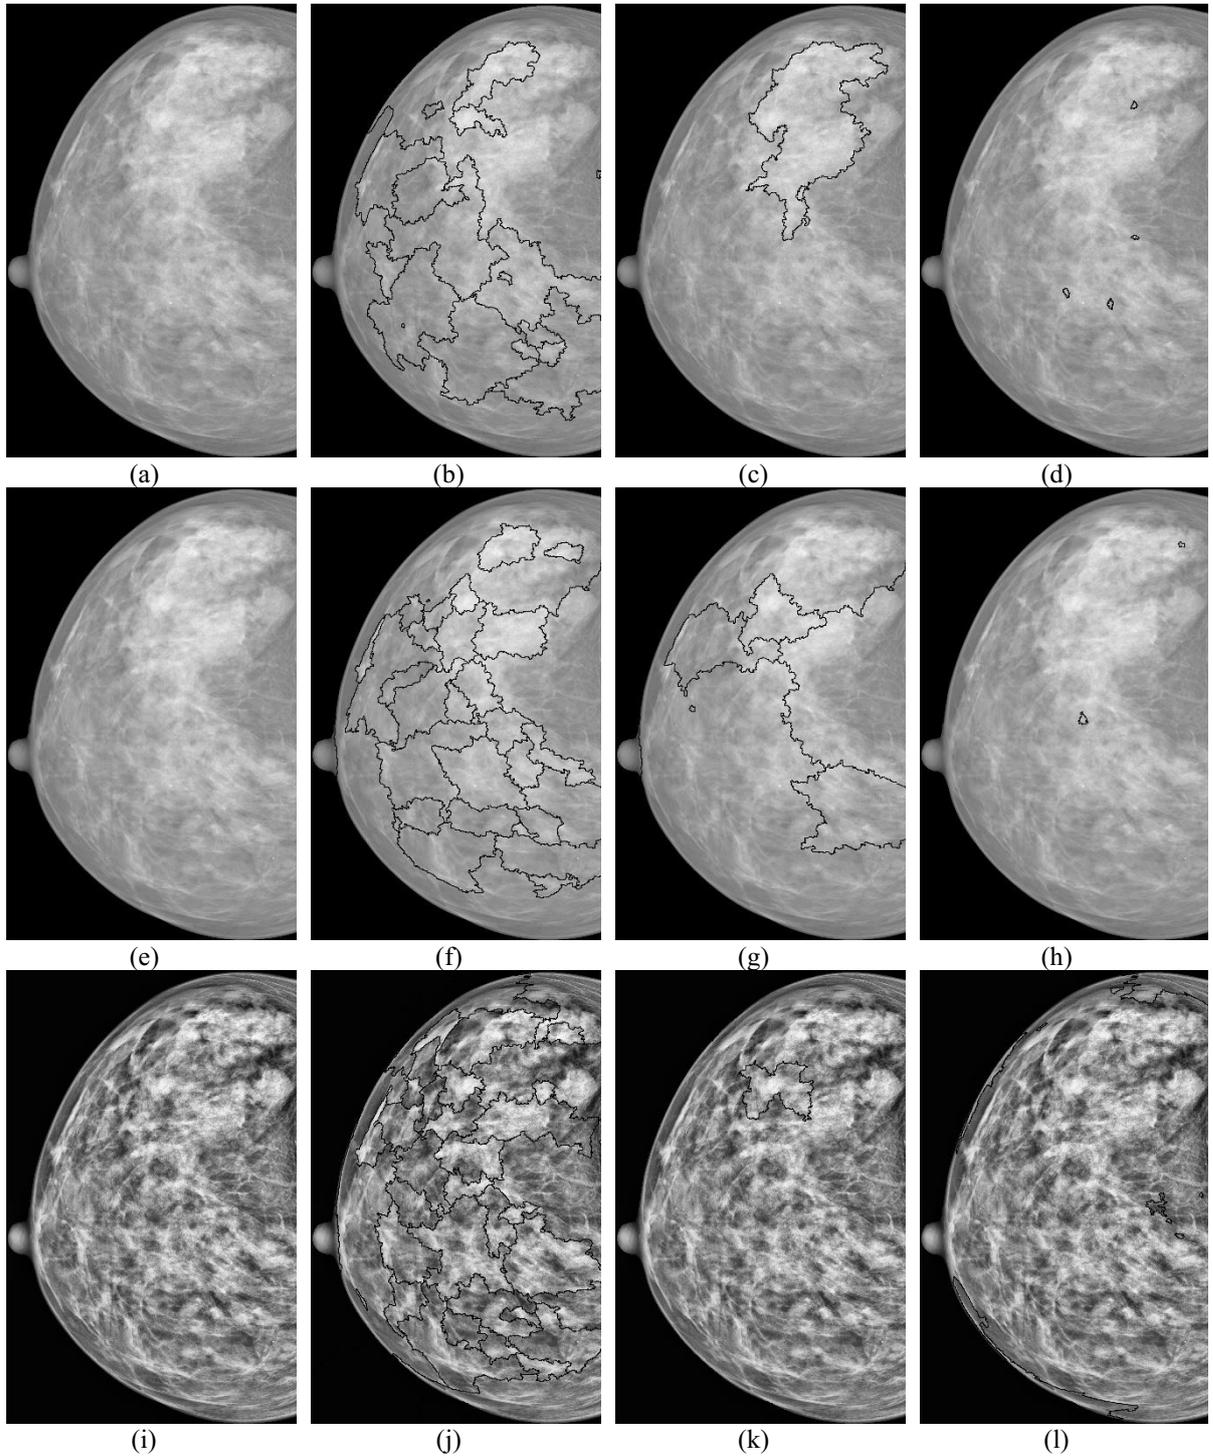
Resultado da segmentação por *watershed* com o formato *diamond*. (a) Original; (b) Original + *diamond* 25; (c) Original + *diamond* 50; (d) Original + *diamond* 100; (e) Wiener; (f) Wiener + *diamond* 25; (g) Wiener + *diamond* 50; (h) Wiener + *diamond* 100; (i) Wavelet + CLAHE; (j) Wavelet + CLAHE + *diamond* 25; (k) Wavelet + CLAHE + *diamond* 50; (l) Wavelet + CLAHE + *diamond* 100.



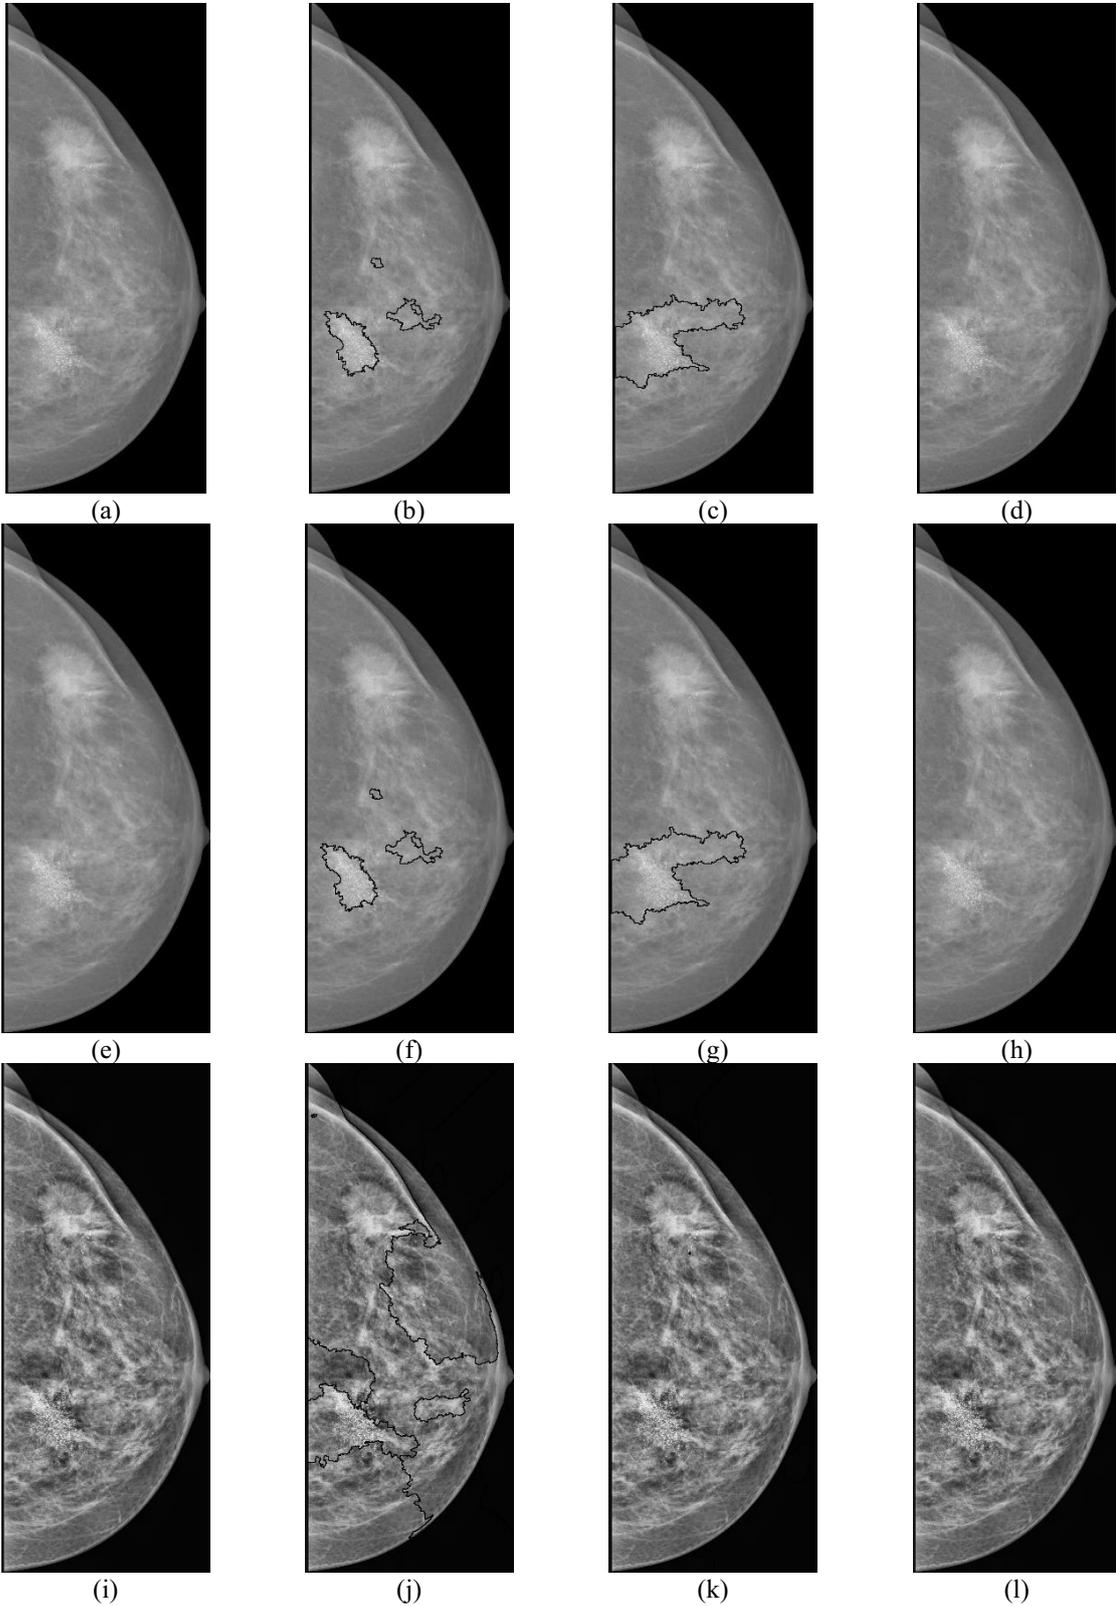
Resultado da segmentação por *watershed* com o formato *disk*. (a) Original; (b) Original + *disk* 25; (c) Original + *disk* 50; (d) Original + *disk* 100; (e) Wiener; (f) Wiener + *disk* 25; (g) Wiener + *disk* 50; (h) Wiener + *disk* 100; (i) Wavelet + CLAHE; (j) Wavelet + CLAHE + *disk* 25; (k) Wavelet + CLAHE + *disk* 50; (l) Wavelet + CLAHE + *disk* 100.



Resultado da segmentação por *watershed* com o formato *diamond*. (a) Original; (b) Original + *diamond* 25; (c) Original + *diamond* 50; (d) Original + *diamond* 100; (e) Wiener; (f) Wiener + *diamond* 25; (g) Wiener + *diamond* 50; (h) Wiener + *diamond* 100; (i) Wavelet + CLAHE; (j) Wavelet + CLAHE + *diamond* 25; (k) Wavelet + CLAHE + *diamond* 50; (l) Wavelet + CLAHE + *diamond* 100.



Resultado da segmentação por *watershed* com o formato *disk*. (a) Original; (b) Original + *disk* 25; (c) Original + *disk* 50; (d) Original + *disk* 100; (e) Wiener; (f) Wiener + *disk* 25; (g) Wiener + *disk* 50; (h) Wiener + *disk* 100; (i) Wavelet + CLAHE; (j) Wavelet + CLAHE + *disk* 25; (k) Wavelet + CLAHE + *disk* 50; (l) Wavelet + CLAHE + *disk* 100.



Resultado da segmentação por *watershed* com o formato *diamond*. (a) Original; (b) Original + *diamond* 25; (c) Original + *diamond* 50; (d) Original + *diamond* 100; (e) Wiener; (f) Wiener + *diamond* 25; (g) Wiener + *diamond* 50; (h) Wiener + *diamond* 100; (i) Wavelet + CLAHE; (j) Wavelet + CLAHE + *diamond* 25; (k) Wavelet + CLAHE + *diamond* 50; (l) Wavelet + CLAHE + *diamond* 100.

