

UNIVERSIDADE DO SAGRADO CORAÇÃO

KAREM DAIANE MARCOMINI

**ESTUDO SOBRE TÉCNICAS DE SEGMENTAÇÃO
APLICADAS EM IMAGENS DIGITAIS: MÉDICAS E DO
COTIDIANO**

BAURU

2009

UNIVERSIDADE DO SAGRADO CORAÇÃO

**ESTUDO SOBRE TÉCNICAS DE SEGMENTAÇÃO
APLICADAS EM IMAGENS DIGITAIS: MÉDICAS E DO
COTIDIANO**

Trabalho de Conclusão de Curso apresentado ao Centro de Ciências Exatas e Sociais Aplicadas como parte dos requisitos para obtenção do título de bacharel em Ciência da Computação, sob orientação da Prof^ª. Ms. Patricia Bellin Ribeiro.

BAURU

2009

KAREM DAIANE MARCOMINI

**ESTUDO SOBRE TÉCNICAS DE SEGMENTAÇÃO APLICADAS EM
IMAGENS DIGITAIS: MÉDICAS E DO COTIDIANO**

Trabalho de Conclusão de Curso apresentado ao Centro de Ciências Exatas e Sociais Aplicadas como parte dos requisitos para obtenção do título de Bacharel em Ciência da Computação, sob orientação da Prof^a. Ms. Patricia Bellin Ribeiro.

Banca Examinadora:

Prof^a. Ms. Patricia Bellin Ribeiro
Universidade do Sagrado Coração

Prof^o. Dr. Kelton Augusto Pontara da Costa
Universidade do Sagrado Coração

Prof^o. Ms. Ronaldo Martins da Costa
Universidade do Sagrado Coração

Bauru, 8 de dezembro de 2009

M3212e

Marcomini, Karem Daiane

Estudo sobre técnicas de segmentação aplicadas em imagens digitais: médicas e do cotidiano / Karem Daiane Marcomini – 2009.
99f.

Orientador: Prof^a. Ms. Patricia Bellin Ribeiro.

Trabalho de Conclusão de Curso (Bacharel em Ciência da Computação) - Universidade do Sagrado Coração - Bauru - SP.

1. Segmentação. 2. Processamento de imagens. 3. Redes neurais. 4. SOM. 5. Filtros. 6. Borda/contorno. I. Ribeiro, Patricia Bellin. II. Título.

Dedico...

Aos meus pais, Romildo e Cida, por estarem sempre presentes, incentivando-me, sendo pacientes e compreensivos.

A Patricia B. Ribeiro pelo incentivo e contribuição tanto no projeto quanto pessoal e profissional.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por me abençoar, por todas as oportunidades que me foram concedidas, pois grandes foram os desafios impostos e com sua ajuda pude superá-los.

Aos meus pais por tudo o que me fizeram, por terem acreditado em mim, por todo o apoio, carinho e incentivo que me deram, pela compreensão que tiveram e que apresentaram nas circunstâncias em que as dificuldades se estabeleciam.

Aos meus irmãos Kátia e Claudinei, por me ajudarem e estarem sempre por perto em todos os momentos, mesmo diante de todas as dificuldades proporcionadas. Minha irmã foi meu espelho em relação aos estudos, pela sua dedicação e esforço para conseguir alcançar seus objetivos, pois suas dificuldades foram enormes.

À minha orientadora Prof^{ra}. Ms. Patricia, pela sua dedicação, disponibilidade, empenho e ajuda em auxiliar-me e por ter acreditado em mim para que pudesse realizar o desenvolvimento desta pesquisa. Além de sempre buscar incentivar a pesquisa em todas suas aulas.

Ao coordenador do curso de ciência da computação, o professor Élvio, por ter se empenhado, buscando o melhor para o curso e procurando sempre atender as necessidades dos alunos.

Aos professores Kelton e Henrique os quais pude ter um contato maior e que estiveram presentes desde o início do curso.

Aos professores Anderson, Richard, Ronaldo, André, Dariel, Luís Alexandre, Marcelo, Luciene e Claudio que passaram toda a base de conhecimento referente às disciplinas específicas do curso.

Ao corpo docente que ministraram as disciplinas básicas do curso e que deram a base e os fundamentos necessários para o conhecimento que pode ser adquirido.

Ao Renan, que é um grande amigo que pude conhecer melhor durante estes quatro anos, pois estive junto comigo desde o início, me aguentando,

compreendendo, ajudando, ensinando, sendo meu companheiro nos trabalhos, podendo estar compartilhando boa parte dos momentos, desde os bons até mesmos os ruins. Uma pessoa maravilhosa e que lembrarei sempre do quanto fez por mim e guardarei sempre como um grande amigo.

Aos meus colegas de turma Thiago (Zezé), Nathália, Junior, Daniel, Samuel, Talita e Carlos que buscamos sempre empenharmos juntos dispostos sempre a se ajudarem e a auxiliar em tudo o que fosse necessário durante o curso, formando além de tudo uma grande amizade.

À Grazi que é uma amiga muito importante, que sempre esteve por perto em todos os instantes, me animando, auxiliando e ajudando em todos os momentos, mesmo nos mais difíceis, agradeço todo o carinho e compreensão que teve por mim.

À Ana Claudia que é uma amiga de infância e que mesmo a distância que foi imposta por determinado tempo, sempre esteve junto de mim em todos os momentos.

À Luana que conheci a pouco, mais se tornou uma amiga essencial e é uma pessoa que adoro muito e agradeço tudo o que fez por mim.

RESUMO

Este trabalho apresenta a proposta de estudo das técnicas de segmentação de imagens através da detecção do contorno, para isso foram empregadas técnicas de redes neurais artificiais e processamento de imagens. Foram utilizadas oito imagens distintas, das quais quatro pertencem à área médica e as outras quatro à cenas cotidianas, com o objetivo de verificar como cada tipo de segmentação se comporta diante da variação dos objetos presentes em cada imagem. Desenvolveu-se também métodos que envolvem a melhoria na qualidade da imagem, para que pudessem ser removidos os ruídos indesejáveis e que contribuísse no resultado final, após a aplicação da segmentação. Os filtros que tornaram o resultado ruim foram inicialmente descartados. Os algoritmos utilizados em processamento de imagens vão desde os básicos até os intermediários. Já na área de rede neurais foi implementada a rede *Self-Organizing Map* (SOM) para verificar se esta, com o uso do algoritmo inteligente, consegue suplantar os métodos de processamento de imagens. Foi aplicado um questionário que consistiu na coleta de dados de 100 pessoas, em que o objetivo de sua aplicação foi o de expor as imagens segmentadas a partir da original e da aplicação de filtros de melhoria. Com base nos dados coletados, foi feita uma análise e em seguida sua tabulação, em que se pôde verificar e identificar a melhor técnica de segmentação escolhida pela maioria das pessoas entrevistadas e o conceito de contorno para cada pessoa.

Palavras-chave: segmentação, processamento de imagens, redes neurais, SOM, filtros, borda/contorno.

ABSTRACT

This work presents the proposal of study of the techniques of segmentation through the detection of the outline of images using artificial neural networks and processing of images. There were used eight different images, of which four belong to the medical area and others four to the daily scenes, with the objective to check how each type of segmentation if it holds before the variation of the present objects in each image. Developed methods that wrap the improvement in the capacity of the image, so that the undesirable noises could be moved and that it was contributing in the final result, after the application of the segmentation. The filters that made the bad result were initially discarded. The algorithms used in vain processing of images from the basic ones up to the intermediaries. Already in the area of neural networks was implemented the net Self-Organizing Map (SOM) to check if this one, with the use of the intelligent algorithm, they manage to supplant the methods of processing of images. Was applied a questionnaire that consisted of the collection of data of 100 persons, in which the objective of his application was it of exposing the images segmented from original and of the application of filters of improvement. On basis of the collected data, an analysis was done and next his tabulate, in which it was possible to check and to identify the best technique of segmentation chosen by most of the interviewed persons and the concept of outline for each person.

key words: segmentation, processing of images, neural network, SOM, filters, edge/outline.

LISTA DE FIGURAS

Figura 2.1 – Etapas do processamento de imagens	19
Figura 2.2– Filtro passa-alta com máscara 3x3.....	23
Figura 3.1– Máscara do filtro Laplaciano.....	25
Figura 3.2 – Máscaras do filtro de <i>Roberts</i>	26
Figura 3.3 – Região da figura original	26
Figura 3.4 – Máscaras do operador de <i>Prewitt</i>	27
Figura 3.5 – Máscaras do operador de <i>Sobel</i>	27
Figura 3.6 – Exemplo de crescimento de região	30
Figura 3.7 – Imagem particionada e a representação da árvore correspondendo aos quadrantes formados.....	31
Figura 3.8 – Representação da imagem original e a aplicação da segmentação de <i>Watershed</i>	32
Figura 3.9 – Relevo topográfico da bacia de <i>Watershed</i> com as linhas divisórias, mínimos e bacias de captação	33
Figura 4.1 – Exemplos de rede <i>Feedforward</i>	36
Figura 4.2 – Exemplos de redes <i>Feedback</i>	36
Figura 4.3 – Modelo de Kohonen	38
Figura 6.1 – Segmentação da imagem Microlobulada pela rede SOM	47
Figura 6.2– Segmentação da imagem da Lena pela rede SOM.....	48
Figura 8.1 - Segmentação da imagem Microlobulada pelo operador <i>Canny</i> e a rede neural SOM	63

LISTA DE TABELAS

Tabela 1 – Tabulação dos dados coletados com o questionário.....	54
--	----

LISTA DE GRÁFICOS

Gráfico 7.1 – Resultado dos Testes de Segmentação da Imagem da Av. Paulista...	55
Gráfico 7.2 – Resultado dos Testes de Segmentação da Imagem do Masp.....	55
Gráfico 7.3 – Resultado dos Testes de Segmentação da Imagem da Lena.....	56
Gráfico 7.4 – Resultado dos Testes de Segmentação da Imagem do Santos Dumont	57
Gráfico 7.5 – Resultado dos Testes de Segmentação da Imagem de Dente na Horizontal	58
Gráfico 7.6 – Resultado dos Testes de Segmentação da Imagem de Dente na Vertical	58
Gráfico 7.7 – Resultado dos Testes de Segmentação da Imagem de Nódulos Mamográficos da Classe Microlobulada.....	59
Gráfico 7.8 – Resultado dos Testes de Segmentação da Imagem de Nódulos Mamográficos da Classe Espiculada.....	60

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Objetivo	15
1.2	Motivação.....	16
1.3	Dispositivo do Trabalho.....	16
2	A IMAGEM E SUAS TÉCNICAS PARA MELHORIA.....	18
2.1	Imagem	19
2.2	Histograma.....	19
2.3	Equalização de Histograma.....	20
2.4	Realce	21
2.5	Filtragem por Mediana	22
2.6	Filtragem Espacial Passa-Alta.....	23
3	SEGMENTAÇÃO DE IMAGENS	24
3.1	Detecção de Bordas/Contornos	25
3.1.1	Laplaciano	25
3.1.2	<i>Roberts</i>	26
3.1.3	<i>Prewitt</i>	26
3.1.4	<i>Sobel</i>	27
3.1.5	<i>Canny</i>	28
3.1.6	<i>Gaussian</i> e <i>Zero Crossing</i>	28
3.2	Ligação de Bordas e Detecção de Fronteiras	29
3.2.1	Crescimento de Região (<i>Region Growing</i>)	29
3.2.2	Divisão e Junção de Regiões (<i>Split and Merge</i>).....	30
3.2.3	Divisor de águas (<i>Watershed</i>)	31
4	REDES NEURAIAS ARTIFICIAIS	34
4.1	Histórico	34
4.2	Arquiteturas das RNAs.....	35
4.3	Aprendizagem	36
4.4	Mapa Auto-Organizável (SOM).....	37
5	APLICAÇÕES DE SEGMENTAÇÃO DE IMAGENS	40

5.1	Áreas de Atuação.....	40
6	MATERIAIS E MÉTODOS	44
6.1	Banco de Imagens	44
6.2	Softwares Utilizados.....	45
6.3	Técnicas de Melhoria	46
6.4	Segmentação através de Processamento de Imagens	46
6.5	Segmentação pela Rede Neural SOM	47
6.6	Análise Estatística	48
7	RESULTADOS E DISCUSSÕES	50
7.1	Técnicas de Realce.....	50
7.2	Técnicas de Segmentação	51
7.3	Resultado da Análise dos Dados	53
8	CONCLUSÕES	61
8.1	Trabalhos Futuros	63
	REFERÊNCIAS	64
	APÊNDICES.....	68

1 INTRODUÇÃO

De acordo com Tomita (1996) as imagens encontram-se presentes em vários locais sob diversas formas tais como: nas fotografias, nos vídeos (estes são compostos por diversos conjuntos de imagens em um determinado tempo para que se tenha a idéia de movimento), em quadros, em esboços, na memória humana ou até mesmo em sonhos. Como objeto de estudo elas podem ser observadas e analisadas sob os mais variados pontos de vista, desde o artístico até o filosófico.

Com o desenvolvimento da tecnologia e o interesse voltado à área de imagens (passando a ser denominado processamento de imagens), surgiram pesquisas visando o estudo do processamento de imagens por computador, onde ocorrem à manipulação numérica da imagem, envolvendo fórmulas matemáticas, que possibilitam sua digitalização para posterior análise, modificações ou extrações de características. Esta área é relativamente nova e seu desenvolvimento foi proporcionado pela evolução dos meios computacionais (TOMITA, 1996).

A obtenção de informações a partir de imagens digitais é um processo a ser aprimorado, pois com a evolução da informática se tornou mais viável o desenvolvimento de métodos mais eficientes para a extração de informações de imagens digitais (GATO *et. al.*, 2001).

“A área de processamento de imagens vem sendo objeto de crescente interesse por permitir viabilizar grande número de aplicações em duas categorias bem distintas: (1) o aprimoramento de informações pictóricas para interpretação humana; e (2) a análise automática por computador de informações extraídas de uma cena” (MARQUES FILHO e VIEIRA NETO, p.1).

No entanto, o computador apresenta grande dificuldade na interpretação das imagens, pois como Nixon e Aguado (2002) apresentam, a visão humana é um sistema sofisticado que atua e detecta os estímulos visuais. O computador e a visão humana possuem como objetivo interpretar dados especiais, que são indexados. Apesar de possuir funções similares não se pode esperar que um sistema de visão computacional reproduza exatamente as funções do sistema visual, pois não

entendemos exatamente como ele realiza suas funções, apenas sabemos que sua principal função é fornecer uma representação do ambiente à nossa volta e a informação que necessitamos para interagir com ele (HAYKIN, 2001).

Gonzalez e Woods (2000) relatam que devido à enorme utilização de imagens em processos do dia-a-dia, o interesse em métodos de processamento de imagens digitais decorre de duas áreas principais de aplicação: melhoria de informação visual para a interpretação humana e o processamento de dados das cenas para a percepção automática através de máquinas, visto que o processamento de imagens é caracterizado por soluções específicas, já que a solução real de um problema específico ainda requer pesquisa e desenvolvimento significativos, pois problemas que funcionam bem em uma área podem se mostrar inadequadas em outra área.

Com isso, várias áreas do conhecimento têm buscado a inserção de técnicas de processamento de imagens, como é o caso das Redes Neurais Artificiais que ganharam grande popularidade nos últimos anos como ferramenta alternativa e às vezes complementar as técnicas clássicas abrangendo áreas como ciência e tecnologia, pois são adaptadas para resolver problemas de cunho geral, tais como aproximação, classificação, categorização, predileção, entre outros, visto que a gama de áreas onde estas podem ser aplicadas é bastante extensa (BRAGA *et al.*, 2000).

Nixon e Aguado (2002) revelam que a área de Visão Computacional teve um grande avanço na abordagem de assuntos relacionados a processamento de imagens abordando, por exemplo, estudos com base de dados biométricos que incluem reconhecimento automático de rostos e reconhecimento de pessoas pela “textura” da sua íris; estes estudos estão em conjunto com fatores biológicos e psicólogos que estudam como funciona o sistema de visão humana e como vemos e reconhecemos objetos e pessoas.

Os sistemas de processamento e análise de imagens têm sido empregados com sucesso na solução de problemas das mais distintas áreas, não envolvendo apenas a computação, como é o caso da medicina, que utiliza as técnicas de processamento como uma ferramenta de auxílio em diagnósticos, onde são analisadas diversas patologias, que através da digitalização de imagens, sistemas são projetados para fornecer um laudo, ou uma “segunda opinião”, para o médico, tornando assim uma ferramenta de auxílio na interpretação de imagens obtidas a partir de raios-X, ressonância magnética, mamografias ou *scans* (RIBEIRO, 2006).

Uma aplicação muito conhecida é a análise de imagens que são obtidas por radar, que vêm sendo aplicado o reconhecimento das placas de carros. A agricultura utiliza muito as técnicas de processamento no sensoriamento remoto, onde uma de suas finalidades é a determinação de fronteiras de cultivo de diferentes produtos. Enfim, é enorme a gama de áreas que utilizam o processamento de imagens.

Fialho (2006) diz que os sistemas de processamento demandam a integração de diversas técnicas relacionadas com a área de processamento de imagens, para isso é necessária a interpretação de imagens, o que na maioria das vezes é dificultada pelas degradações inseridas nos processos de geração e visualização devido a problemas que podem vir a ocorrer pela digitalização, pois dependendo do modo em que é realizada, a imagem digitalizada pode vir a apresentar ruídos indesejáveis.

Com isso, para a obtenção de uma imagem de boa qualidade pode-se direcionar o processamento de imagens para realizar a correção de alguns problemas como, por exemplo, defeitos criados pela aquisição ou degradações da imagem, ocorridos devido ao tempo ou qualquer outro fator. Este procedimento envolve técnicas de realce da imagem para extração desses ruídos (FIALHO, 2006).

Em processamento de imagens, há técnicas que permitem a extração de diversas características dos objetos pertencentes a uma imagem, uma delas é a realização da segmentação, a qual permite a extração dos objetos contidos na cena. A segmentação faz parte de um processo maior, que é a classificação da imagem, esta pode ser realizada através de diversas formas, uma delas refere-se a extração da borda/contorno dos objetos, podendo representar uma cena apenas com as áreas de interesse (CARVALHO, 2003).

1.1 Objetivo

Este trabalho possui como objetivo realizar a segmentação de imagens digitais, para isso serão comparados os diversos métodos de segmentação que envolvem tanto a área de processamento digital de imagens quanto a de redes neurais artificiais, esta faz uso de algoritmo inteligente, verificando quais dentre as várias técnicas empregadas realiza a melhor segmentação, ou seja, qual é capaz de extrair melhor o contorno dos objetos.

1.2 Motivação

Artero e Tommaselli (2002) relatam que embora exista um grande número de técnicas de segmentação de imagens digitais, a maioria delas não consegue apresentar bons resultados em todas as situações, podendo ocorrer omissão de alguns detalhes no contorno da imagem, esses se diferenciam pela quantidade de características que são capazes de extrair dos objetos pertencentes à cena, e isto pode corresponder ao maior ou menor detalhamento. O menor detalhamento torna o resultado não significativo devido a não resolução de todos os problemas presentes na imagem, isto ocorre pelo fato da técnica empregada não promover a solução de um problema específico (NEVES, 2001).

O tipo da imagem também influencia na escolha do método a ser aplicado, visto que cada uma possui características específicas, podendo ocorrer variâncias no formato dos objetos pertencentes à cena, baixo ou alto contraste, qualidade, equipamento de digitalização, entre outros (RIBEIRO, 2006).

Estes tipos de problemas podem afetar diretamente áreas as quais o processamento de imagens é empregado. Um dos principais problemas que pôde ser verificado é em imagens médicas, onde os detalhes demonstram extrema importância e sua omissão pode ser prejudicial aos laudos e diagnósticos médicos.

1.3 Dispositivo do Trabalho

Além deste capítulo o trabalho está composto de mais sete capítulos, conforme a descrição sumária abaixo:

Capítulo 2: A Imagem e as Técnicas para a sua Melhoria – Define brevemente o processamento de imagens e apresenta as técnicas que permitem a melhoria da imagem.

Capítulo 3: Segmentação de Imagens – Relata as segmentações de imagens digitais, relacionadas à área de processamento de imagens, e suas respectivas características.

Capítulo 4: Redes Neurais Artificiais – Histórico, conceitos de uma forma geral, e a breve explicação da rede *Self-Organizing Map* (SOM), a qual será empregada para realização da segmentação de imagens.

Capítulo 5: Aplicações de Segmentação de Imagens – De uma forma geral, estão mencionados alguns trabalhos que foram desenvolvidos atualmente que envolvem a área de segmentação de imagens.

Capítulo 6: Materiais e Métodos – Descrição dos materiais utilizados para a implementação do projeto e detalhamento da metodologia aplicada.

Capítulo 7: Resultados e Discussões – Apresentação dos resultados obtidos com as técnicas aplicadas e avaliação e discussão dos resultados colhidos.

Capítulo 8: Conclusões – Conclusões finais sobre o trabalho.

Referências Bibliográficas – Bibliografia consultada e utilizada no decorrer do desenvolvimento da pesquisa.

2 A IMAGEM E SUAS TÉCNICAS PARA MELHORIA

Silva (2003) revela que o processamento de imagens consiste em técnicas que tentam extrair informações das imagens, como textura, densidade, volume e área, por exemplo. As técnicas que tratam da compressão, reconstrução e detecção de bordas em objetos, também são do escopo do processamento de imagens. O interesse nesta área tem crescido nos últimos anos, inúmeras técnicas têm sido pesquisadas para aplicações diversas como *biolook* (para retratos falados), biometria, fotogrametria, aplicações militares, automação industrial, aplicações médicas e outras. Este interesse tem resultado em pesquisas para desenvolvimento de hardware e software.

Torres (2006) diz que as técnicas de processamento pode ser dividida em dois estágios o pré-processamento e análise de imagens. O pré-processamento consiste em técnicas que procuram melhorar a qualidade de imagens para a interpretação humana ou de máquina. Já a análise de imagens retira as informações necessárias para uma aplicação específica, onde a entrada do processamento é uma imagem enquanto a saída é sua descrição, podendo também ser entendido como redução dos dados mantendo o conteúdo de informação relevante para uma dada aplicação. A Figura 2.1 representa, de uma forma simples, os procedimentos/etapas que são realizadas para processar uma imagem, que vai desde a aquisição da imagem até a análise final do resultado.

No âmbito de processamento de imagens, serão vistas as diversas técnicas que envolvem o pré-processamento, ou seja, a melhoria em alguns pontos da imagem, removendo dados indesejáveis e realçando os importantes, pois o ruído é um problema muito comum e pode assumir várias formas diferentes, trazendo resultados indesejáveis e requer diferentes técnicas de remoção, e isto pode ser visto através dos itens dispostos a seguir.

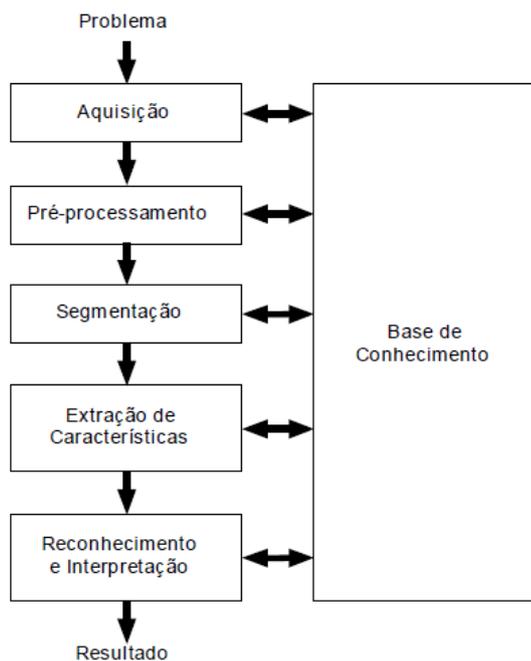


Figura 2.1 – Etapas do processamento de imagens

Fonte: Marques Filho e Vieira Neto, 1999, p. 9.

2.1 Imagem

Uma imagem monocromática pode ser descrita matematicamente por uma função $f(x,y)$ da intensidade luminosa, sendo seu valor proporcional ao brilho (ou nível de cinza) da imagem naquele ponto, já as imagens coloridas com padrão RGB (*Red, Green, Blue*) que são formadas pelas cores primárias aditivas.

A aquisição da imagem tem como função a conversão de uma imagem em uma representação numérica. Para isso deve-se ter um digitalizador que converte o sinal elétrico analógico em informação digital, isto é, que pode ser representada através de *bits* 0 ou 1. Em seguida ocorre a conversão de uma cena tridimensional em bidimensional, onde a própria câmera ou outro dispositivo realiza essa tarefa. (MARQUES FILHO e VIEIRA NETO, 1999).

2.2 Histograma

O Histograma de uma imagem é a representação dada pela distribuição estatística ou percentual dos níveis de cinza em termos do número de *pixels* com

cada nível que a imagem possui. Ele fornece o número de *pixels* e não sua localização na cena, permitindo também dar uma descrição global da imagem. Através da visualização do histograma obtemos uma indicação da qualidade quanto ao nível de contraste¹ e brilho médio (se a imagem é predominantemente clara ou escura). O Histograma pode revelar também se há ruído. Cada elemento é calculado pela equação 2.1. (FIALHO, 2006; MARQUES FILHO e VIEIRA NETO, 1999; NIXON e AGUADO, 2002).

$$p_r(r_k) = \frac{n_k}{n} \quad (2.1)$$

Onde:

$$0 \leq r_k \leq 1$$

$k = 0, 1, \dots, L-1$, onde L é o número de níveis de cinza da imagem digitalizada;

n = número total de *pixels* na imagem;

$p_r(r_k)$ = probabilidade do k -ésimo nível de cinza;

n_k = número de *pixels* cujo nível de cinza corresponde a k .

Marques Filho e Viera Neto (1999) afirmam que embora o histograma de uma imagem forneça diversas informações qualitativas (qualidade subjetiva global da imagem, presença ou não de ruído etc.) e quantitativas (nível de cinza mínimo, médio e máximo, predominância de *pixels* claros e escuros etc.) somente podem ser extraídas dispondo-se da imagem propriamente dita.

2.3 Equalização de Histograma

A técnica de equalização de histograma é utilizada para obter a máxima variância do histograma obtendo um aumento ou também alargamento do contraste² dos objetos na cena, realçando diferenças de tonalidades e possibilitando o melhor discernimento das informações contidas na imagem. No histograma equalizado há

¹ Alto e baixo contraste estão relacionados ao espaçamento médio entre as raias do histograma. Já o termo “bom contraste” exprime a distribuição equitativa das raias do histograma ao longo da escala de cinza.

² Contraste é a medida qualitativa que está relacionada com a distribuição dos tons de cinza em uma imagem.

uma distribuição mais uniforme (redistribuição) dos níveis de cinza (o número percentual de *pixels* de qualquer nível de cinza é praticamente o mesmo). No histograma da imagem original os níveis de cinza estão concentrados nas baixas intensidades. Esta técnica também pode ser aplicada apenas em trechos de imagens, realçando detalhes de pequenas porções (SOUZA e CORREA, 2007; MARQUES FILHO e VIEIRA NETO, 1999; FIALHO, 2006). A fórmula de equalização do histograma é através da função de distribuição acumulada (cdf – *cumulative distribution function*) e pode ser expressa pela equação 2.2.

$$s_k = T(r_k) = \sum_{j=0}^k \frac{n_j}{n} = \sum_{j=0}^k p_r(r_j) \quad (2.2)$$

Onde:

$$0 \leq r_k \leq 1$$

$$k = 0, 1, \dots, L-1$$

2.4 Realce

De acordo com Marques Filho e Viera Neto (1999) o objetivo das técnicas de realce é processar uma certa imagem de modo que a resultante seja mais adequada que a original, ou como Torres (2006) diz, para que o resultado seja mais apropriado para uma aplicação específica, pois o resultado pode ser bom em uma aplicação e não corresponder ao esperado em outra. Marques Filho e Viera Neto (1999) ressaltam que é importante verificar que a interpretação depende do conhecimento prévio do observador a respeito das imagens analisadas e que não existem técnicas capazes de resolver todos os problemas que uma imagem digital possa apresentar. O melhoramento da imagem é obtido através de técnicas como melhoramento de contraste ou filtragens aplicadas com finalidades específicas enfatizando características de interesse ou recuperando imagens que sofreram algum tipo de degradação devido à introdução de ruído, perda de contraste ou borramento (CARVALHO, 2003).

Torres (2006) afirma que não há uma teoria geral para o realce de imagens, pois quando a imagem é processada para a interpretação visual, o observador é

quem julga a qualidade do desempenho de um método particular. A avaliação visual da qualidade da imagem é um processo subjetivo, tornando difícil elaborar uma definição do que seja uma boa imagem através do qual se possa comparar o desempenho do algoritmo. Porém quando o problema envolve processamento de imagens para percepção por máquinas, a tarefa de avaliação é um pouco mais fácil, mas mesmo assim o critério de desempenho deve ser bem definido, pois o analista terá que realizar diversas tentativas antes de estabelecer uma abordagem adequada de processamento.

2.5 Filtragem por Mediana

Uma das principais dificuldades do método de suavização é que ele borra as bordas e outros detalhes. Se o objetivo for alcançar a redução de ruído em vez de borrar, uma abordagem alternativa consiste no uso de filtros por mediana. Isto é, o nível de cinza de cada *pixel* é substituído pela mediana dos níveis de cinza na vizinhança daquele *pixel*, ao invés da média, sendo que a característica a ser preservada é a agudeza das bordas (GONZALEZ e WOODS, 2000; MARQUES FILHO e VIERA NETO, 1999).

Carvalho (2003 *apud* FALCON, 2002) revela que o objetivo do filtro da mediana é substituir o *pixel* central de uma matriz, geralmente 3x3, pelo valor que estiver na mediana desses *pixels* ordenados de forma crescente de nível de cinza. Este filtro baseia-se no fato de que se um ponto for um ruído, ao colocar em ordem crescente o ponto central e sua vizinhança, o ruído tende a ficar no extremo da ordem disposta, onde ao aplicar o filtro, este é substituído pelo valor mediano do conjunto de *pixels* da matriz. Diferentemente do filtro da média, que também utiliza uma matriz de *pixels*, porém substitui cada *pixel* da imagem pela média de seus vizinhos.

2.6 Filtragem Espacial Passa-Alta

Este filtro é aplicado à imagem para destacar os *pixels* brilhantes circundados por *pixels* mais escuros, sendo aplicado para a detecção de pontos isolados.

Segundo Gonzalez e Woods (2000) a forma para implementar um filtro passa-alta indica que é necessário que o filtro possua coeficientes positivos próximo ao centro e negativos na periferia, assim como o exemplo visto na Figura 2.2 de uma máscara 3x3.

$$\frac{1}{9} \times \begin{array}{|c|c|c|} \hline -1 & -1 & -1 \\ \hline -1 & 8 & -1 \\ \hline -1 & -1 & -1 \\ \hline \end{array}$$

Figura 2.2– Filtro passa-alta com máscara 3x3

Fonte: Marques Filho e Vieira Neto, 1999, p. 96.

Os autores continuam dizendo que na implementação do filtro, a soma dos coeficientes é zero, assim quando a máscara está sobre uma área de níveis de cinza constante ou de pequena variação, a saída é zero ou muito pequena. A redução do valor médio de uma imagem para zero implica que a imagem deve ter alguns níveis de cinza negativos, como empregamos apenas níveis positivos, o resultado da filtragem envolve alguma forma de mudança na escala e/ou exclusão (“*clipping*”) de modo que os níveis de cinza do resultado final cubram o intervalo [0, L-1] (GONZALEZ e WOODS, 2000; MARQUES FILHO e VIERA NETO, 1999).

3 SEGMENTAÇÃO DE IMAGENS

A segmentação consiste no processo de identificação de objetos que possuam características semelhantes em uma imagem. Segmentar uma imagem consiste em particioná-la em regiões de *pixels* relevantes para uma dada aplicação, ou seja, dividir a imagem em unidades significativas dos objetos de interesse, mas a subdivisão depende do problema que se pretende resolver, pois devem ser segmentados apenas os objetos de interesse que compõe a cena, não havendo a necessidade de segmentar os objetos que não são relevantes ao projeto que se deseja desenvolver (MARQUES FILHO e VIEIRA NETO, 1999; GONZALEZ e WOODS, 2000). A segmentação consiste em duas tarefas básicas: identificação e delineamento. A identificação indica a posição aproximada do objeto de trabalho na cena e o delineamento extrai sua extensão na imagem. Seres humanos executam a primeira tarefa com relativa facilidade, mas o computador é capaz de executar a segunda com muito mais precisão que os seres humanos. A dificuldade da máquina na identificação de objetos se deve à falta de uma descrição global dos objetos na forma de um modelo matemático (LIMA, 2006).

Pratt (2007) diz que a segmentação não envolve classificação de cada segmento. O segmentar apenas subdivide uma imagem; ele não tenta reconhecer os diferentes segmentos ou seus relacionamentos.

Uma boa segmentação significa que “as regiões de uma segmentação devem ser uniformes e homogêneas com respeito a alguma característica (níveis de cinza, por exemplo). Regiões adjacentes precisam ter valores significativamente distintos em relação à característica nas quais elas são homogêneas. Por fim, as bordas das regiões precisam ser simples, ou seja, únicas e contínuas” (ESPINDOLA e CÂMARA, 2007 *apud* Haralick e Shapiro, 1985).

Gonzalez e Woods (2000) revelam que a segmentação é uma das tarefas mais difíceis em processamento de imagens, pois determina o sucesso ou fracasso na análise da imagem.

3.1 Detecção de Bordas/Contornos

Segundo Fialho (2006) a borda é uma das técnicas básicas utilizadas pela visão humana no reconhecimento de objetos. Ela é definida por uma mudança ou mesmo uma descontinuidade e variação abrupta na intensidade dos níveis de cinza entre duas regiões relativamente homogêneas. Encontrando-se os pontos em que a derivada é um ponto máximo, tem-se a borda dos objetos, pois este é um processo de localização e realce dos *pixels* da borda, aumentando o contraste entre o contorno e o fundo. Este tipo de detecção é a abordagem mais comum para a detecção de descontinuidades significativas nos níveis de cinza, pois os pontos e linhas isoladas não são ocorrências freqüentes na maioria das aplicações práticas, um operador que é sensível a estas mudanças operará como um detector de bordas.

3.1.1 Laplaciano

“Embora o filtro laplaciano seja insensível à rotação e, portanto capaz de realçar ou detectar bordas em qualquer direção, seu uso é restrito devido a sua grande suscetibilidade a ruído” (NEVES, 2001, p. 10).

Gonzalez e Woods (2000) revelam que o Laplaciano possui a exigência de que o coeficiente associado ao *pixel* central seja positivo e que os *pixels* externos sejam negativos. Este filtro não é muito utilizado para a detecção de bordas, pois é muito sensível ao ruído e produz bordas duplas, sendo incapaz de detectar a direção da borda. A Figura 3.1 demonstra a máscara utilizada pelo filtro laplaciano.

0	-1	0
-1	-4	-1
0	-1	0

Figura 3.1– Máscara do filtro Laplaciano

Fonte: Gonzalez e Woods, 2000, p. 301.

3.1.2 Roberts

O método de Roberts é o detector de bordas mais antigo. Possui algumas desvantagens, uma delas é que certas arestas são mais realçadas que outras, mesmo com magnitudes iguais. O resultado de sua aplicação pode ser uma imagem com altos valores de cinza em regiões com limites bem definidos e baixos valores em regiões com limites suaves (NOGUEROL, 2008).

Gonzalez e Woods (2000) relatam que este filtro pode ser implementado através do uso de máscaras de tamanho 2x2, como no exemplo da Figura 3.2. Essas máscaras são chamadas de operadores cruzados de gradiente de *Roberts*. O diferencial é que máscaras de tamanho par são incômodas de se implementar, por tal motivo é necessário o uso de valores absolutos, que são calculados através das equações 2.5.

$$M_x = \begin{array}{|c|c|} \hline 1 & 0 \\ \hline 0 & -1 \\ \hline \end{array} \quad M_y = \begin{array}{|c|c|} \hline 0 & 1 \\ \hline -1 & 0 \\ \hline \end{array}$$

Figura 3.2 – Máscaras do filtro de *Roberts*

Fonte: Gonzalez e Woods, 2000, p. 143.

$$\nabla f = |z_5 - z_8| + |z_5 - z_6| \quad \nabla f = |z_5 - z_9| + |z_6 - z_8| \quad (2.5)$$

Onde, z_n corresponde ao nível de cinza da imagem original, que pode ser representada através da Figura 3.3, onde a mesma está representada por 9 *pixels* apenas.

z_1	z_2	z_3
z_4	z_5	z_6
z_7	z_8	z_9

Figura 3.3 – Região da figura original

3.1.3 Prewitt

O operador de *Prewitt* é mais resistente ao ruído, pois diferencia e suaviza a imagem, atenuando os efeitos negativos do ruído, pode ser utilizado para implementar a equação 2.6. Este utiliza duas máscaras que são convolucionadas

com a original, podem ser visualizadas na figura 3.4. Este operador é muito semelhante ao operador de *Sobel*, o que os diferencia são os pesos dos pontos vizinhos do *pixel* central, onde *Prewitt* possui menos peso, produzindo bordas diagonais mais atenuadas (GONZALEZ e WOODS, 2000; NOGUEROL, 2008).

$$\nabla f = |(z_7 + z_8 + z_9) - (z_1 + z_2 + z_3)| + |(z_3 + z_6 + z_9) - (z_1 + z_4 + z_7)| \quad (2.6)$$

$$M_x = \begin{array}{|c|c|c|} \hline -1 & -1 & -1 \\ \hline 0 & 0 & 0 \\ \hline 1 & 1 & 1 \\ \hline \end{array} \quad M_y = \begin{array}{|c|c|c|} \hline -1 & 0 & 1 \\ \hline -1 & 0 & 0 \\ \hline -1 & 0 & 1 \\ \hline \end{array}$$

Figura 3.4 – Máscaras do operador de *Prewitt*

Fonte: Gonzalez e Woods, 2000, p. 143.

3.1.4 *Sobel*

O operador de *Sobel* realça as bordas da imagem em certas direções, baseando-se na aplicação do gradiente. Possui uma propriedade que permite detectar se um *pixel* pertence ou não a borda independente dos vizinhos, isto é, cada *pixel* é processado de forma independente. É muito sensível ao ruído e a iluminação (NOGUEROL, 2008).

O operador de *Sobel* utiliza-se de máscaras 3x3 e isso o torna menos sensível ao ruído em relação ao filtro de *Roberts*, que utiliza máscara 2x2, tornando os resultados mais precisos e a computação mais complexa (FIALHO, 2006). A matriz representando a máscara do operador de *Sobel* está representada na Figura 3.5.

$$G_x = \begin{array}{|c|c|c|} \hline -1 & -2 & -1 \\ \hline 0 & 0 & 0 \\ \hline 1 & 2 & 1 \\ \hline \end{array} \quad G_y = \begin{array}{|c|c|c|} \hline 1 & 0 & -1 \\ \hline 2 & 0 & -2 \\ \hline 1 & 0 & -1 \\ \hline \end{array}$$

Figura 3.5 – Máscaras do operador de *Sobel*

Fonte: Neves, 2001, p. 9.

3.1.5 *Canny*

De acordo com Fialho (2006) o filtro de *Canny* é considerado uma das técnicas mais robustas e de melhor desempenho computacional, pois seu criador J. Canny (1986) definiu um conjunto de metas que o detector deveria possuir que são: taxa de erro (deveria achar e detectar somente as bordas, onde nenhuma deveria faltar), localização (distância entre os *pixels* encontrados pelo detector e a borda real deve ser a menor possível), resposta (o detector não deve identificar múltiplos *pixels* de borda onde somente exista um *pixel*). Isto foi realizado para que pudesse atingir o objetivo de ser um detector de bordas ótimo, pois busca a eliminação da fragmentação das bordas causadas pelo ruído da imagem (VALE e POZ, 2002).

Vale e Poz (2002) dizem que o *Canny* realiza a localização do gradiente de maior amplitude da imagem, de forma a minimizar o número de bordas da região, o procedimento é feito por uma técnica chamada de “não máxima supressão” que atua reduzindo a espessura dos contornos de um *pixel*. Em seguida é realizada a limiarização, em que os detectores de borda trabalham apenas com um limiar T qualquer, já o operador *Canny* utiliza dois limiares, um de alta e um de baixa. Se o valor de uma borda ultrapassa o limiar de baixa o mesmo é aceito, enquanto se o valor for menor que o limiar de baixa o mesmo é rejeitado. Para os valores de borda situados entre os dois limiares serão aceitos os *pixels* que estiverem conectados de forma a se obter uma boa resposta. A vantagem deste procedimento é que mais pontos são conectados facilitando a determinação de contornos e dando maior consistência aos resultados obtidos.

3.1.6 *Gaussian e Zero Crossing*

Zero Crossing é a técnica de detecção de bordas baseada na função laplaciana, pois procura os zeros que constituem a função (onde a função de *laplace* muda de sinal) que geralmente corresponde a zonas de contorno. Já o filtro Gaussiano suaviza a imagem reduzindo as variações de cores ou níveis de cinza (RUEDA, 2007).

3.2 Ligação de Bordas e Detecção de Fronteiras

As técnicas descritas na seção 3.1 detectam descontinuidades de intensidade, onde raramente caracterizam completamente uma fronteira, isto se deve a ruídos, quebra de fronteiras devido à iluminação não uniforme e a outros efeitos que introduzem descontinuidades de intensidades. Portanto os algoritmos de detecção de borda são seguidos de procedimentos de detecção de fronteiras, desenvolvido para juntar e organizar os *pixels* de bordas em fronteiras significativas (GONZALEZ e WOODS, 2000).

A descontinuidade é responsável por particionar uma imagem com base na informação de uma mudança abrupta do nível de cinza ou textura, sendo normalmente utilizado na detecção de pontos isolados, linhas e bordas

3.2.1 Crescimento de Região (*Region Growing*)

O método de crescimento de região é realizado através do agrupamento dos *pixels* vizinhos, de mesma amplitude (buscando a similaridade entre os *pixels*), ou sub-regiões em regiões maiores para formar uma região segmentada (GONZALEZ e WOODS, 2000; PRATT, 2007; SILVA, 2003).

Pratt (2007) revela que este método proporciona razoavelmente a segmentação de cenas simples, com poucos objetos e pouca textura, mas não possui um bom desempenho em cenas mais complexas.

Este processo inicia-se com a escolha de um *pixel* (deve ser quase sem ruído) ou grupo de *pixels* (para fornecer algum grau de tolerância para o ruído nas imagens) como semente, escolha esta que pode ser manual ou automática e o *pixel* semente deve fazer parte do objeto a segmentar. A escolha manual é realizada pelo usuário que seleciona um conjunto de sementes que são colocadas em áreas de homogeneidade visual (SILVA, 2003; PRATT, 2007).

Silva (2003) diz que após a escolha da semente os *pixels* vizinhos são testados, um de cada vez, e adicionados a semente para o crescimento de região, os novos *pixels* são adicionados de acordo com a similaridade sob o critério de uniformidade, o procedimento é repetido até que nenhum *pixel* seja mais adicionado, sendo que as regiões adjacentes da parte semeada (n) seja reunida em uma

fronteira comum (PRATT, 2007). O objeto é então representado por todos os *pixels* aceitos durante o procedimento de crescimento.

Podemos encontrar alguns problemas ao realizar o crescimento de região, que são: a seleção de sementes que representam adequadamente as regiões de interesse (se for escolhido de forma errônea, pode gerar fragmentação ou mistura das regiões que não caracterizam o objeto de interesse e caso o processo seja inicializado em pontos distintos, pode levar a distintos crescimentos de regiões); a seleção de propriedades apropriadas para a inclusão de pontos nas várias regiões durante o processo de crescimento. A seleção de critérios de similaridade depende do problema em consideração, mas também do tipo de dados (imagem) disponíveis. Outro problema é o estabelecimento de uma condição de parada, pois o crescimento de região deve parar quando nenhum outro *pixel* satisfizer os critérios de inclusão naquela região. A vantagem deste método está no fato de ser capaz de segmentar corretamente regiões que possuem a mesma propriedade e estão espacialmente separadas, podendo haver a conexão dessas regiões (GONZALEZ e WOODS, 2000; SILVA, 2003).

A Figura 3.6 demonstra um exemplo de segmentação por crescimento de região, com as representação das etapas que o algoritmo realiza.

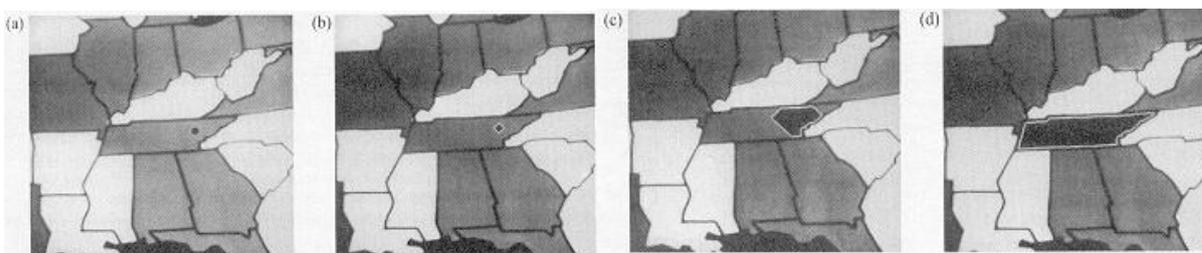


Figura 3.6 – Exemplo de crescimento de região

Fonte: Gonzalez e Woods, 2000, p. 328.

3.2.2 Divisão e Junção de Regiões (*Split and Merge*)

Silva (2003) revela que em uma imagem pode haver a subdivisão (*splitting*) da mesma em um conjunto de regiões arbitrárias e disjuntas. Para uma imagem quadrada, podemos subdividi-la em quadrantes cada vez menor. Mas não podemos realizar apenas a subdivisão, pois a partição final poderá conter regiões adjacentes

com propriedades idênticas, por isso é feita a fusão destas regiões seguindo o mesmo critério da divisão. A combinação da divisão com o agrupamento das regiões é denominado *splitting-and-merging*. A técnica considera a imagem, inicialmente, como único segmento, divide-a em seguida em quatro sub-regiões, se a região não atender ao critério de homogeneidade dos níveis de cinza, após atingir o limite, as regiões vizinhas e similares são agrupadas.

A Figura 3.7 representa uma imagem quadrada, onde é realizada a divisão em quadrantes, como pode ser visto esta divisão pode ser representada por uma árvore, por tal motivo esta representação pode ser chamada de *quadtree*, pois cada nó possui exatamente quatro descendentes (GONZALEZ e WOODS, 2000). A raiz da árvore corresponde à imagem inteira e cada nó corresponde a uma subdivisão (neste caso apenas o R_4 foi novamente dividido).

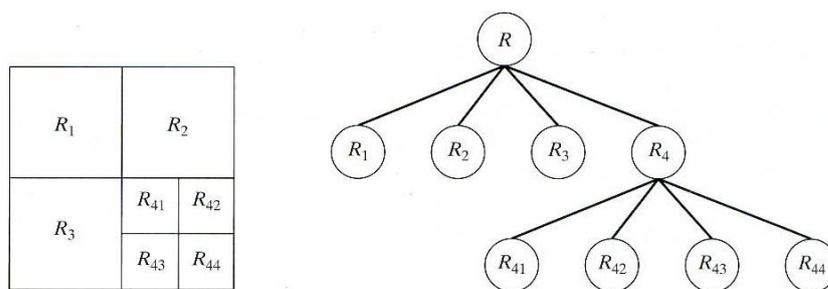


Figura 3.7 – Imagem particionada e a representação da árvore correspondendo aos quadrantes formados

Fonte: Gonzalez e Woods, 2000, p. 329.

3.2.3 Divisor de águas (*Watershed*)

De acordo com Silva (2003) a segmentação de *Watershed* pode ser imaginada como duas ou mais regiões de planícies separadas por uma ou mais montanhas. Cada região tem seu próprio vale (mínimo), e estes vales são perfurados e inundados. A água penetra verticalmente preenchendo a superfície topográfica. Durante o preenchimento dois ou mais fluxos provenientes de mínimos diferentes podem unir-se. Os diques (picos) construídos para evitar a junção de águas constituem as linhas divisórias, também conhecida como linhas de *Watershed*. Os níveis de cinza de uma imagem indicam a altitude no ponto de

relevo. As regiões de interesse são tratadas como bacias de captação ou retenção (*Catchment Basin* – CB).

A segmentação de *Watershed* consiste na determinação das bacias de retenção a partir de primitivas do tipo de região e contorno. Este método pode ser relacionado a segmentação através do gradiente morfológico, onde os contornos dos objetos da imagem, que podem ser visualizados em regiões onde os níveis de cinza mostram uma rápida variação, porém grande parte das bordas resultantes não pertence ao contorno dos objetos. Portanto a aplicação do *Watershed* diretamente na imagem gera o fenômeno da segmentação excessiva (*oversegmentation*), pois este método é muito sensível a ruído, com isso, bacias simples tendem a produzir resultados que são mais segmentados, por tal motivo devem ser aplicados métodos no algoritmo de *Watershed* para reduzir a segmentação (SILVA, 2003; PRATT, 2007). Como podemos ver na representação 3.8 a imagem original e após a aplicação do algoritmo de segmentação utilizando apenas a técnica de *Watershed* causando a excessiva inundação dos mínimos.



Figura 3.8 – Representação da imagem original e a aplicação da segmentação de *Watershed*

A Figura 3.9 representa a segmentação de *Watershed* como uma bacia hidrográfica, onde cada mudança na similaridade dos *pixels* ocasiona a diferença entre os picos e os mínimos (vales).

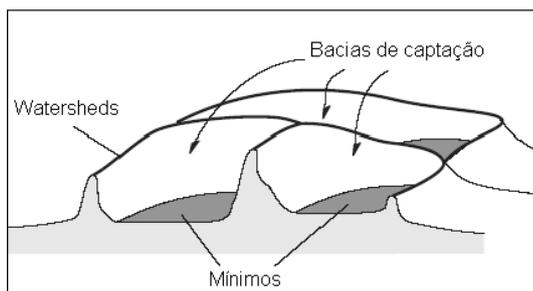


Figura 3.9 – Relevo topográfico da bacia de *Watershed* com as linhas divisórias, mínimos e bacias de captação

4 REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais (RNAs) é uma estrutura inspirada no funcionamento do cérebro humano, cujo objetivo é realizar tarefas sobre as quais os humanos são melhores.

Na literatura podemos encontrar definições como:

“Uma rede neural é uma máquina que é projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse; a rede é normalmente implementada utilizando-se componentes eletrônicos ou é simulada por programação em um computador digital” (HAYKIN, 2001, p. 28).

“As RNAs são sistemas paralelos e distribuídos compostas por unidades de processamento simples (nodos) que calculam determinadas funções matemáticas (normalmente não-lineares). Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais. Na maioria dos modelos, estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede [...]” (BRAGA *et al.*, 2000, p. 1).

4.1 Histórico

O primeiro modelo artificial de um neurônio biológico teve início em 1943 com o trabalho de McCulloch e Pitts, onde se concentraram em descrever o modelo e apresentar as capacidades computacionais do que apresentar as técnicas de aprendizado, este modelo realizaria a computação de qualquer função computável. O segundo trabalho mais significativo foi o de Hebb (1949) com o livro *The Organization of Behavior*, onde é apresentado pela primeira vez a formulação de uma regra de aprendizagem através da variação dos pesos de entrada dos neurônios (HAYKIN, 2001; BRAGA *et al.*, 2000).

Haykin (2001) relata que Resenblatt introduziu uma nova abordagem para o reconhecimento de padrões (1958) em seu trabalho sobre o *perceptron*, método inovador de aprendizagem supervisionada. Seu trabalho foi intitulado teorema da convergência do *perceptron*. Em 1960, Widrow e Hoff usaram o algoritmo do mínimo quadrado médio para formular o *Adaline (Adaptive Linear Element)*. Mas em 1969 veio o livro de Minsky e Papert que demonstraram que existem limites para o *perceptron* de única camada em relação aquilo que podem calcular. Já em 1973 surgiram os mapas auto-organizáveis utilizando aprendizagem competitiva, foi um trabalho de simulação computacional desenvolvido por Malsburg. Nos anos 80 ressurgiu o interesse por redes neurais, e Grossberg estabeleceu um novo princípio de auto-organização conhecido como teoria da ressonância adaptativa (ART). Em 1982, Hopfield criou a técnica de realimentação em redes neurais, ou seja, é a execução de redes recorrentes com conexões sinápticas simétricas. Neste mesmo ano Kohonen publica um artigo sobre os mapas auto-organizáveis utilizando uma estrutura de rede unidimensional ou bidimensional. Ackley, Hinton e Sejnowski (1985) desenvolveram a máquina de *Boltzmann*, que foi a primeira realização bem sucedida de uma rede neural de múltiplas camadas, apesar do algoritmo de aprendizagem da máquina não ter se mostrado tão eficiente do ponto de vista computacional como o de retropropagação (*back-propagation*) que foi desenvolvido apenas no ano de 1986 por Rumelhart, Hinton e Williams.

4.2 Arquiteturas das RNAs

A arquitetura de uma RNA define a forma como os neurônios estão estruturados. Poder ser diferenciada pelo em função do número de camadas ou em relação ao tipo de conexões que podem haver entre os neurônios.

Em relação aos tipos de conexões podem classificadas em: (a) *feedforward* e (b) *feedback*.

(a) **Feedforward** são redes em que todos os pontos de conexão são passados para frente. A rede é totalmente conectada, ou seja, cada neurônio de uma camada da rede está conectado a todos os neurônios da camada anterior, conforme demonstrado na Figura 4.1 (BRAGA *et al.* 2000; HAYKIN, 2001).

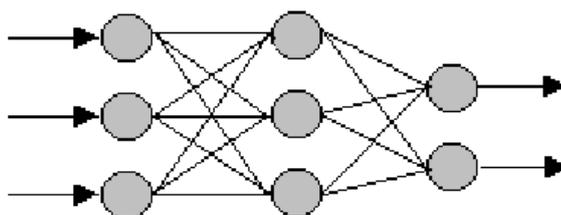


Figura 4.1 – Exemplos de rede *Feedforward*

(b) **Feedback** (ou recorrente) possui ao menos um laço de realimentação, onde podemos ter a saída ligada a entrada da mesma camada, camadas anteriores, camadas alternadas. Podemos visualizar o exemplo conforme a Figura 4.2

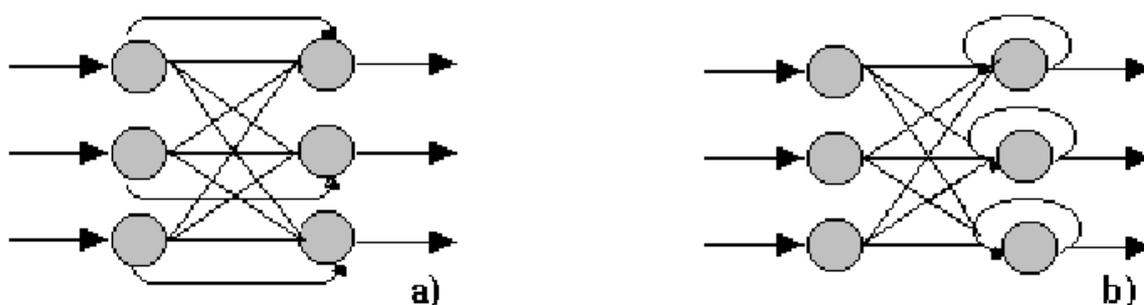


Figura 4.2 – Exemplos de redes *Feedback*

“A maneira pela qual os neurônios de uma rede neural estão estruturados está intimamente ligada com o algoritmo de aprendizagem usado para treinar a rede [...]” (HAYKIN, 2001, p. 46).

4.3 Aprendizagem

O processo de aprendizagem de uma rede neural consiste em, através de exemplos, com base em um conjunto de entradas e as funções neurais (ajustes dos pesos sinápticos) irão gerar os valores de saída.

Braga *et al.* (2000) relata que o aprendizado é desenvolvido através de diversos métodos de treinamento, e o que diferenciam esses métodos é o algoritmo de aprendizado. Estes algoritmos basicamente diferem pela maneira pela qual o ajuste dos pesos é feito.

Há duas formas de aprendizado, o **supervisionado** este é definido como se um professor fornecesse a resposta correta ao treinamento da rede (HAYKIN, 2001). Durante o treinamento de uma RNA, pares de entradas e saídas desejadas são apresentadas. O objetivo é ajustar os parâmetros da rede (os pesos sinápticos), de forma que o erro seja minimizado, pois pequenos ajustes são feitos nos pesos a cada etapa do treinamento até que a saída da rede seja igual à saída real (AZEVEDO *et al.*, 2000; BRAGA *et al.*, 2000). Já o outro tipo de aprendizado é o **não-supervisionado** que oferece apenas os pares de entrada e não requer um professor, isto é, não há saída desejada. A RNA recebe padrões de entrada e organiza estes arbitrariamente em categorias. Quando uma entrada é apresentada a rede, a RNA fornece uma resposta de saída indicando a classe a qual a entrada pertence (AZEVEDO *et al.*, 2000).

4.4 Mapa Auto-Organizável (SOM)

A rede SOM (*Self-Organizing Map*) também é conhecida como Mapa de Kohonen, a rede leva este nome por ter uma estrutura topológica, porém não é fixa podendo assumir diversos formatos, embora o quadrado seja o mais comum. A definição do formato mais adequado depende do problema atacado e da distribuição dos dados, geralmente o formato é definido por tentativa de erro (BRAGA *et al.*, 2000).

Haykin (2001) revela que o interesse na construção de mapas topográficos artificiais se concentra que aprendam através da auto-organização, inspirando-se na neurobiologia.

É uma rede do tipo não supervisionada, utiliza aprendizado competitivo, onde o padrão de entrada faz com que os neurônios disputem entre si para serem ativados, ou seja, para saber qual dessas unidades será a vencedora e terá seus pesos atualizados no treinamento. As unidades de entrada são diretamente conectadas as unidades de saída, e estas podem estar ligadas entre si via conexões laterais (BRAGA *et al.*, 2000; HAYKIN, 2001).

De acordo com Haykin (2001) cada neurônio está totalmente conectado com todos os neurônios de fonte da camada de entrada. Esta estrutura consiste no arranjo de linhas e colunas dos neurônios.

“A topologia básica da rede possui 2 camadas: a camada de entrada $1 \times N$ que lê os vetores-padrão apresentados à rede e uma camada de saída composta de uma matriz $M \times M$ de neurônios que forma uma resposta uni ou bidimensional ao padrão apresentado” (Veja Figura 4.3) (AZEVEDO *et al.*, 2000, p. 101).

Braga *et al.* (2000) relata que a vizinhança define quantos neurônios em torno do vencedor terão seus pesos ajustados, ou seja, é definida a área de influência do neurônio vencedor, ou seja, serão atualizados os pesos do neurônio vencedor e seus vizinhos que estão dentro de um determinado raio. Durante o treinamento a taxa de aprendizado e o raio são continuamente decrementados.

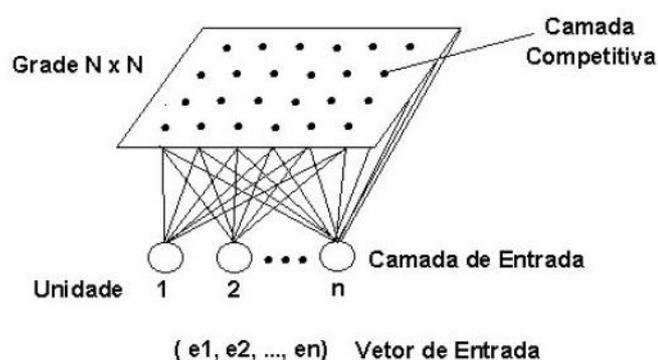


Figura 4.3 – Modelo de Kohonen

Azevedo *et al.* (2000) revela que essa rede é útil principalmente no reconhecimento de padrões, quando as classes a que devem pertencer os elementos a serem reconhecidos não são conhecidos inicialmente.

O algoritmo de treinamento da rede, que o mesmo pode ser dividido nos seguintes passos (HAYKIN, 2001; AZEVEDO *et al.*, 2000):

- 1 – **Inicialização:** atribuem os pesos de forma randômica às conexões entre os neurônios das camadas de entrada e de saída, ou seja, seus valores são adquiridos de forma aleatória. É importante que este vetor de pesos seja normalizado.
- 2 – **Amostragem:** retira-se uma amostra do vetor de x (entrada) que possui dimensão igual a m e representa o padrão de ativação que é apresentado a grade.
- 3 – **Seleção do neurônio vencedor:** calcula o valor de “distância” quadrática para cada neurônio de saída, em relação ao neurônio de entrada. Este valor de proximidade entre o valor de entrada e cada neurônio da saída j de rede é medido

através do parâmetro d_j de Distância Euclidiana³. A partir desta distância deve-se encontrar o neurônio vencedor, ou seja, é aquele que possui o padrão mais “próximo” ou “semelhante” ao apresentado.

4 – **Atualização:** Apenas os pesos das conexões entre os neurônios de entrada e a região composta pelo neurônio vencedor e sua vizinhança serão atualizados a cada interação. A atualização dos pesos se dá através da equação 4.3.

$$w_{ij}(t+1) = w_{ij}(t) + n(t)(e_j(t) - w_{ij}(t)) \quad (4.3)$$

O termo $n(t)$ corresponde à taxa de aprendizagem do algoritmo e também tem seu valor alterado a cada interação, segundo a relação disposta na equação 4.4.

$$n(t) = n(0) \left(1 - \frac{t}{T} \right) \quad (4.4)$$

Onde $n(0)$ é o valor inicial de n que decresce ao longo das interações t , e T corresponde ao valor máximo de interações possíveis.

5 – **Continuação:** o passo 2 deve ser repetido até que não sejam observadas modificações significativas no mapa de características.

Haykin (2001) revela que o algoritmo SOM de Kohonen é simples de ser implementado, apesar de matematicamente ser difícil de analisar suas propriedades.

³ Distância Euclidiana: seja E um espaço euclidiano. Dado os vetores x e $y \in E$, definimos a distância entre x e y , o comprimento do vetor $x - y$, isto é: $d(x,y) = \|x - y\| \rightarrow d(x,y) = \sqrt{(x - y, x - y)}$

5 APLICAÇÕES DE SEGMENTAÇÃO DE IMAGENS

Neste capítulo serão apresentados alguns projetos desenvolvidos na área de segmentação de imagens digitais, abordando pesquisas que estão sendo realizadas atualmente, demonstrando a importância da realização desta pesquisa.

5.1 Áreas de Atuação

Inácio (2007) buscou trabalhar com imagens radiográficas dentárias visando correlacionar as estruturas topológicas dentárias com patologias do foro estomatológico. Para isso realizou a melhoria na qualidade da imagem, onde envolveram técnicas de minimização de ruído e de técnicas de manipulação de contraste. Após a melhoria foram aplicadas técnicas de segmentação por contorno, as quais foram testadas para que pudesse ser avaliada qualitativamente a periodontite, baseada na medição na perda de massa óssea alveolar. Por fim foi proposto um protótipo de um sistema de informação e processamento para radiologia odontológica.

Noguerol (2008) realizou testes com extratores de borda (*Prewitt, Roberts, Sobel, Canny, Laplacian*) com o objetivo de desenvolver um sistema que visa auxiliar exames patológicos, o *software* procura objetos que poderão ser ovos, encontrados os objetos, serão identificados através de sua morfometria (área, perímetro, circularidade, textura e coloração).

Botelho (2007) utiliza o filtro de *Sobel* para a extração das bordas de edificações, porém posteriormente ao filtro realiza o processo de binarização seguido do afinamento das bordas. Seu projeto não visava à detecção de todos os pontos da cena, e sim a delimitação apenas das bordas das edificações visando à realização do contorno utilizando cores, das quadras delimitadas pelo processo de segmentação, buscando-se a eliminação de objetos isolados. Por fim foi realizada a poligonação dos telhados.

Mossmann (2006) apresentou um trabalho de conclusão de curso envolvendo análise de imagens médicas, em que para a efetuação da detecção de bordas utilizou diversos filtros além do *Canny*, porém concluiu que em sua pesquisa o operador que conseguiu obter a maior quantidade de detalhes das imagens médicas foi o *Canny*.

Santos (2002) aplicou a transformada de *Watershed* para a detecção de nódulos em mamas densas, onde seguiu os seguintes passos: apresentação da imagem original; cálculo do gradiente interno e externo para toda imagem; cálculo e armazenamento dos *pixels* mais brilhantes, que serão marcados na imagem; inversão do gradiente e cálculo das distâncias para montar o esqueleto através da análise da vizinhança, para eliminar pontos gerando zonas de influência; utilizando o valor absoluto do gradiente constrói-se uma espécie de “topografia”, que são as regiões homogêneas e planas; “inundação das regiões baixas”, a partir de pontos mínimos agindo como sementes para o crescimento de regiões, onde a parada é o gradiente da imagem; áreas marcadas pelos diferentes “níveis de água” formam os segmentos separados formados pelas linhas da transformada de *Watershed*; a imagem é binarizada e o nódulo é destacado do restante da imagem, obtendo assim o resultado final.

Para minimizar esse problema, Silva (2003) em seu projeto de mestrado, referente a segmentação de imagens da região pélvica, foram aplicados dois métodos, onde o primeiro foi o proposto por Bucher que baseia-se na extração manual de marcadores e na transformação homotópica do gradiente pela reconstrução geodésica, este não obteve resultados satisfatórios. Já o segundo método foi o baseado em Bueno que baseia-se na geração de imagens mosaicos através do multi-crescimento de regiões e em seguida implementou-se a transformada de *Watershed*.

Gato et. al. (2001) desenvolveu testes utilizando o algoritmo de Crescimento de Região para realizar a extração de feições automáticas. Foram desenvolvidos seis testes que proporcionaram as seguintes mudanças no algoritmo: no teste 1 utilizou o critério de similaridade fixando valores para a média (máscara 3x3) e o desvio padrão (correspondendo a 2); no teste 2 variou o tamanho da máscara (3x3, 5x5, 7x7, 9x9, 11x11, 13x13 e 15x15) e fixou o desvio padrão em 2; no teste 3 fixou a máscara em 3x3 e variou o desvio padrão (2, 6, 10 e 14); no teste 4 variaram os valores da máscara e do desvio padrão; no teste 5 utilizou a comparação de médias

amostrais (α), onde os parâmetros utilizados foram semente (11x11, 11x11 e 3x3), varredura (3x3) e α (0.5%, 10% e 0.5%); no teste 6 foi realizada a segmentação através do limiar capturado pelo histograma da imagem. Em cada um desses casos foi visto que trouxeram pontos positivos bem como negativos.

Silva e Carvalho (2002) utilizaram o algoritmo de Crescimento de Região para que as imagens finais servissem de análise dos nódulos pulmonares, isso foi realizado em pelo algoritmo em 3D por agregação de *voxes*, o qual permite que os médicos tenham maior interatividade e controle sobre a segmentação e determinação dos parâmetros (limiar, fatia e semente) necessários. O controle é realizado através da barreira (usuário do sistema limita a região de interesse) e da borracha (permite ao médico apagar, antes ou depois da segmentação, estruturas indesejáveis).

No modelo apresentado por Galvanin (2007) utilizou-se a segmentação por *Split and Merge* para realizar a extração do contorno de telhados, em que inicialmente foi realizada a divisão do modelo digital de elevação (redução da complexidade da cena retirando informações associadas a objetos baixos) e em seguida realizou-se a fusão *bayesiana* que consiste na redução da fragmentação das regiões detectadas na divisão recursiva (preservação dos objetos com altura maior, facilitando o reconhecimento do contorno). A segunda etapa consistiu na extração do contorno do telhado usando um modelo *Markov Random Field* no contexto *bayesiano* (modela as relações espaciais).

Simões (2000) apresenta a rede neural MLP para a realização da segmentação de imagens por classificação de cores. Tomou-se diferentes redes (conjunto de redes treinadas com um determinado conjunto de exemplos e com diferentes números de neurônios), cada rede apresenta seu próprio ponto de aprendizado. O subconjunto de treinamento foi tomado do conjunto de validação (este utilizou todos os *pixels* da imagem). Os resultados obtidos para a imagem contínua foi próximo de 100%, já para a imagem degradê foi de 87%.

No projeto apresentado por Ribeiro (2006), foi utilizada a RNA para classificar imagens mamográficas, se são normais ou possuem nódulos, diante do contorno. Para a obtenção dos atributos de textura foi utilizada a rede neural SOM e Gaussianas. Realizou-se os mesmos testes com a rede *MultiLayer Perceptron* (MLP), onde foram feitos os treinamentos e validações, obtendo um melhor resultado. Ao final, obteve-se a separação de 5 classes possíveis de contornos,

tanto utilizando tanto a rede SOM quanto a MLP, esta porém apresentou melhores resultados. Este classificador foi incorporado ao sistema CAD que está sendo desenvolvido.

6 MATERIAIS E MÉTODOS

Este projeto tem por base o desenvolvimento de pesquisas experimentais e laboratoriais (MÁTTAR NETO, 2002, p. 147), as quais estão baseadas na utilização de estatísticas a partir da coleta de dados e suas respectivas análises, pois primeiramente, deve-se programar o que se pretende colher e como a coleta deverá ser realizada, a pretensão final e como os dados serão tratados. Para isto, tem-se a proposta de realizar a análise das formas que podem ajudar na melhoria em relação ao processo de extração de características pertencentes à imagem, visto que, são muitas as técnicas que realiza a segmentação.

As pesquisas laboratoriais foram divididas em três fases: a primeira objetiva a remoção de ruídos indesejáveis através da aplicação de técnicas de melhoria; a segunda visa realizar a segmentação por contorno utilizando as técnicas de processamento de imagens; e por fim a terceira fase, com a segmentação por contorno obtida através da rede neural SOM. Já para a realização das pesquisas experimentais teve que ser criado um banco de imagens próprio.

6.1 Banco de Imagens

Para a realização dos ensaios experimentais foi criado um banco de imagens próprio, onde estas foram selecionadas visando à diferenciação das características dos objetos pertencentes à imagem.

Este banco totalizou oito imagens digitalizadas, onde destas quatro correspondem a imagens médicas e as outras quatro a imagens cotidianas.

Das quatro imagens médicas, duas correspondem a radiografias de nódulos mamográficos pertencentes às classes microlobulada e espiculada, as quais foram cedidas do banco de imagens do LAPIMO (Laboratório de Análise e Processamento de Imagens Médicas e Odontológicas) do Departamento de Engenharia Elétrica EESC/USP. As outras duas imagens médicas são de radiografias dentárias cedidas pela Universidade de São Paulo – Faculdade de Odontologia de Bauru. As

digitalizações destas imagens foram feitas em *scanner* laser *Lumiscan*, salvando-as e dispondo-as em formato *Tagged Image File Format* (tiff).

As quatro imagens restantes representam cenas cotidianas e foram obtidas através da *Internet* e estão representadas pelas imagens: da Lena⁴, de Santos Dumont⁵, do Museu de Arte de São Paulo (Masp⁶) e da Avenida Paulista de São José do Rio Preto⁷ e estão dispostas em formatos *bitmap* e *Join Photographic Experts Group* (jpeg).

Estes tipos de imagens foram escolhidos buscando a variação das figuras que as envolve, pois variam desde imagens que envolvem o dia-a-dia das pessoas, como as fotos (Lena e Santos Dumont) e de locais de cidades (Av. Paulista e Masp) até mesmo as que são desconhecidas pela grande maioria como as radiografias dentárias e de nódulos mamográficos.

6.2 Softwares Utilizados

Para o desenvolvimento dos ensaios laboratoriais a codificação dos algoritmos necessários foi realizada utilizando o software *Matlab* versão 7.0 devido a sua facilidade de manipulação com relação às imagens. Utilizou-se o software *ImageJ*⁸ versão 1.42, para gerar e salvar os histogramas das imagens, onde puderam ser verificados os valores referentes aos níveis de cinza: a média, o início e término e a maior quantidade por pixel.

A análise estatística foi realizada no *Microsoft Excel* 2007, onde foi realizada a inclusão dos dados dispostos na aplicação dos questionários e onde foram tabulados automaticamente os resultados finais e foram gerados os gráficos de cada imagem, onde representou a quantidade de pessoas que escolheram determinada técnica de segmentação, isto para cada uma das oito imagens.

⁴ Obtido em: <http://www.cs.uiowa.edu/~jorgen/ImagesWav/lena.png>

⁵ Obtido em: <http://www.century-of-flight.net/Aviation%20history/up%20to%20WW%201/images/8a.jpg>

⁶ Obtido em: <http://biocita.files.wordpress.com/2009/01/masp.jpg>

⁷ Obtida em: <http://img78.imageshack.us/img78/6787/161fx.jpg>

⁸ Obtido em: <http://rsbweb.nih.gov/ij/download.html>

6.3 Técnicas de Melhoria

A aplicação da melhoria sobre a imagem foi de extrema importância para a correção das imagens realizando a remoção de informações desnecessárias e de ruídos indesejáveis, que são causados por diversos fatores, tais como intensidade luminosa, qualidade, contraste, cor, brilho, desgaste físico ou causado pela digitalização, entre outros, e as técnicas empregadas auxiliaram na remoção ou mesmo no aparecimento de novos ruídos.

Foram desenvolvidos apenas os algoritmos da mediana, passa-alta e de equalização, pois são muitos os algoritmos que realizam esta tarefa, podendo ser encontrados filtros até melhores, mais o objetivo principal concentra-se no estudo das técnicas de segmentação, ficando as de realce como complemento, pois estas técnicas contribuem desde a própria visualização e até mesmo no resultado final, ou seja, neste caso, após a aplicação dos algoritmos de segmentação.

Os algoritmos puderam ser criados através da consulta ao sistema de ajuda do próprio *Matlab*, pois o mesmo possui funções específicas para a realização destas tarefas.

6.4 Segmentação através de Processamento de Imagens

Foram criados diversos algoritmos para realizar a tarefa de segmentação de imagens através da sub-área da computação de processamento de imagens, estes algoritmos envolvem desde as técnicas mais básicas – *Canny*, *Laplacian*, *Prewitt*, *Roberts*, *Sobel* e *Zero Crossing*, até as mais avançadas – Crescimento de Região, *Split and Merge* e *Watershed*.

Os algoritmos destas técnicas mais básicas foram obtidas usando funções do próprio *Matlab*, pois buscou-se a segmentação automática dos objetos para todas as imagens, não realizando nenhum controle na sensibilidade do contorno, mesmo o *software* utilizado permitindo esta alteração. Já para as técnicas mais avançadas realizou-se a implementação dos algoritmos, utilizando o sistema de ajuda do *Matlab* e o próprio site do *software* onde contribuiu para a construção dos algoritmos de

Crescimento de Região, *Split and Merge* e o de *Watershed*⁹, que sofreram adaptações buscando enquadrar-se ao proposto neste trabalho.

6.5 Segmentação pela Rede Neural SOM

Por fim utilizou-se a rede neural artificial para verificar a proximidade com as técnicas de processamento de imagens. A rede utilizada foi a SOM devido a pequena quantidade de imagens utilizadas, pois a rede *Multilayer Perceptron* também é capaz de realizar a segmentação no entanto é necessário uma grande quantidade de imagens para compor o banco.

Para o desenvolvimento da rede utilizou-se também o *Matlab*. A mudança que ela proporciona e a diferencia das outras técnicas de segmentação é que a rede utiliza padrões RGB, não trabalhando apenas com as bases numéricas. No treinamento da rede, o contorno foi extraído através de cálculos entre a proximidade dos valores RGB das imagens em cinza e as cores branca e preta que foram estabelecidas como padrões, visando a utilização dos extremos para gerar a segmentação.

No final do treinamento a rede neural apresentou a imagem binarizada e em seguida teve que ser aplicado um algoritmo que visa plotar o contorno branco sobre a imagem criada em preto. A diferença entre a imagem binarizada e a aplicada o contorno pode ser vista na Figura 6.1, onde é demonstrada uma imagem de nódulo mamográfico pertencente à classe microlobulada, e na Figura 6.2, em que é apresentada a imagem da Lena.



Figura 6.1 – Segmentação da imagem Microlobulada pela rede SOM

⁹ Obtido em: <http://www.mathworks.com/matlabcentral/fileexchange/13628-edge-detection-and-segmentation>.



Figura 6.2– Segmentação da imagem da Lena pela rede SOM

6.6 Análise Estatística

A análise estatística foi realizada através da coleta de dados obtida pela realização de questionários que incluiu as imagens originais na escala de cinza, imagens originais segmentadas e após a aplicação do filtro da mediana, exceto no algoritmo de Crescimento de Região que foi utilizado após a aplicação do filtro passa-alta.

A análise dos dados foi realizada de forma visual, onde cada pessoa observou a mesma imagem processada com as diferentes técnicas de segmentação e também após serem aplicados os filtros selecionados.

Foram coletados os dados de 100 pessoas, sendo esses estudantes da própria Universidade (USC) do curso de Ciência da Computação do 1º ao 4º ano, pois estes atuam na manipulação de imagens, e a escolha ocorreu devido à falta de um número expressivo de profissionais especializados (como por exemplo, arquitetos, dentistas, médicos) em cada área e devido ao curto período de tempo para a apresentação do resultado. A coleta foi realizada entre o período de 06/11/2009 à 17/11/2009, das quais 65 foram entrevistadas pessoalmente, aplicado o questionário. Os questionários foram impressos em papel fotográfico, visando estabelecer a maior qualidade das imagens, disponibilizado no tamanho A₄ (210mm de largura por 297mm de altura) e na orientação de paisagem, sendo impressas nove folhas, em que a primeira continha todas as imagens originais em cinza e nas oito folhas restantes foram incluídas cada tipo de imagem com os tipos de segmentação estudados. Os dados das 35 pessoas restantes foram obtidos através

da disponibilização do mesmo questionário na plataforma *syllabus*¹⁰, onde os alunos da própria Universidade que possuem acesso a plataforma poderiam realizar o download das imagens para sua visualização e posteriormente inserir a resposta desejada no site, estes dados foram obtidos através do download do arquivo em formato *text*.

Depois de coletadas todas as respostas, realizou-se a tabulação dos dados para verificar qual dentre as técnicas de segmentação obteve melhor resultado, determinando se realmente em imagens diferentes as técnicas reagem da mesma forma, apresentando assim o resultado final da melhor segmentação a técnica escolhida pela maioria entrevistada.

¹⁰ Temporariamente disponibilizado no link: <http://syllabus.usc.br/course/view.php?id=1567>

7 RESULTADOS E DISCUSSÕES

Neves (2001) relata que devido ao grande avanço tecnológico pode-se verificar a utilização cada vez maior do computador na solução de diversos problemas, assim como nas tarefas de extração de informações de imagens e uma dessas tarefas é a segmentação. Este trabalho estuda as diversas técnicas de segmentação de imagens em níveis de cinza, sendo que essas técnicas são baseadas na detecção de contornos.

7.1 Técnicas de Realce

Neves (2001) afirma que após a digitalização podem ser feitas diversas transformações na imagem até conseguir a solução do problema para o qual ela está sendo usada, essas transformações podem ser agrupadas nos seguintes conjuntos: filtragem, análise, compressão e síntese de imagens.

Com base nos problemas que as imagens podem vir a possuir, independente do motivo ou meio em que apareceram ou foram ocasionados, procurou-se testar alguns filtros de melhoria, visto que são muitos os métodos que realizam tal procedimento, no entanto observou-se que a maioria deles é bem específico para cada tipo de imagem, pois cada um realça algum detalhe mais importante ou remove algum tipo de ruído que determinada imagem adquiriu, pois um filtro pode ser ótimo para determinada imagem e não ser tão bom para outra, isto acaba tornando a escolha do método difícil devido à grande quantidade existente. As técnicas de realce possuem como principal objetivo processar uma imagem, de modo que o resultado seja mais apropriado, para uma aplicação específica, do que a original (GONZALEZ e WOODS, 2000). Por tal motivo foram implementados os mesmos algoritmos de melhoria para todos os tipos de imagem, não levando em consideração os pontos que necessitavam ser melhorados e sim como cada técnica reagiria à aplicação do filtro.

Foram utilizados apenas os filtros da mediana, de equalização e o passa-alta, pois concentrou-se mais nas técnicas de segmentação do que a procura dos filtros de melhoria. No Apêndice A.1 podem ser observadas as imagens da Av. Paulista de São José do Rio Preto em cinza e com a aplicação dos filtros de melhoria, já as imagens do Masp estão dispostas no Apêndice B.1, as da Lena estão apresentadas no Apêndice C.1, as de Santos Dumont conforme o Apêndice D.1, já no Apêndice E.1 estão as imagens de radiografias dentárias na horizontal, e as de radiografias dentárias na vertical está disposta no Apêndice F.1, e por fim foram empregas essas técnicas nas imagens de radiografias de nódulos mamográficos pertencentes às classes microlobulada (Apêndice G.1) e espiculada (Apêndice H.1)

Os filtros de equalização juntamente com o de passa-alta foram descartados após serem aplicados nas imagens, pois trouxeram uma maior quantidade de ruídos e o resultado após a aplicação da segmentação não foi significativo, portanto não foram utilizados, empregando apenas o filtro da mediana e a segmentação sobre a imagem original. Porém quando aplicado à segmentação por Crescimento de Região, o filtro passa-alta obteve resultado mais expressivo se comparado com o filtro de equalização e o da mediana, por tal motivo, foi utilizado no Crescimento de Região à segmentação sobre a imagem original e após a aplicação do filtro passa-alta.

Este fato demonstra que as técnicas aplicadas variam conforme o procedimento utilizado, pois cada imagem interage diferente com a forma com que e cada método é empregado, formando e funcionando em conjunto, pois funcionam bem com uma combinação específica, e não são em todas as circunstâncias que a são obtidos bons resultados.

7.2 Técnicas de Segmentação

São muitas as técnicas que realizam a segmentação da imagem, assim como as áreas em que são aplicadas, isto faz com que surjam métodos específicos, e com combinações específicas, além de que a própria segmentação pode ter outras aplicações além da detecção do contorno, como por exemplo, a compressão, a reconstrução e a síntese de imagens.

Foi utilizado o operador *Canny*, o qual trouxe o maior detalhamento, encontrando uma maior quantidade de bordas e dando uma maior continuidade de suas linhas, no entanto houve o aparecimento de objetos que não fazem parte do contorno, pois acabou causando certa poluição visual em algumas imagens, como por exemplo, nas de nódulos mamográficos, em qualquer mudança no nível de cinza foi incluída como contorno mesmo não pertencendo.

A segmentação através do Crescimento de Região gerou certo problema, pois buscou-se alcançar o melhor resultado através da segmentação automática, onde foi estabelecido um valor padrão para o limiar e para a semente, no entanto isso provocou contrastes entre as classes de imagens, pois cada classe aceitou esses valores de maneiras diversas, na imagem da Lena por exemplo, quando aplicado sobre a original nem encontrou bordas, no entanto sobre as imagens de câncer o resultado foi, de certa forma, significativo, porém obteve-se resultados melhores mais não seguiu um padrão, isso pode ser constatado apenas de forma visual durante a realização de testes no algoritmo implementado.

O operador de *Laplacian* ressaltou as linhas dos objetos, não havendo o extremo detalhamento, o que revelou um contorno sem muita poluição visual, ou seja, não trouxe tantos objetos que não pertencem ao contorno, isso gerou certa fidelidade da imagem original.

No operador de Roberts o contorno apareceu como um pontilhamento, logo as linhas ficaram extremamente descontínuas, com pouquíssimo detalhamento dos objetos. Os operadores de *Prewitt* e de Sobel trouxeram pouco detalhamento das imagens, mas com contornos mais expressivos se comparado ao operador de *Roberts*, as linhas apresentaram-se um pouco mais contínuas.

Na rede neural SOM ocorre certa mudança no contorno cada vez em que o treinamento é realizado, devido aos pesos serem aleatórios, porém os resultados não saíram dos padrões esperados, sendo essa diferença entre cada treinamento mínima. A rede busca o contorno dos objetos, e isto faz com que essas linhas sejam mais contínuas, no entanto não traz grande detalhamento de todos os objetos, pois ela busca contornos mais relevantes, não gerando assim a poluição visual dos pelo excessivo detalhamento.

O algoritmo de *Split and Merge* não ficou como o esperado, pois provocou o aparecimento de linhas duplas, que se interligavam casualmente por alguns *pixels*,

dando a aparência de deformamento devido às linhas aproximarem-se de retas, não possuindo a idéia de circularidade que certos objetos necessitam.

O *Matlab* possui um algoritmo próprio para realizar a segmentação por *Watershed*, no entanto como pode ser visto no capítulo 3.2.3, esta técnica causa o chamado *oversegmentation*, que é a extrema segmentação dos objetos e para retirar isso, foram aplicados vários testes antes do resultado apresentado. Alguns desses testes não removiam a extrema segmentação ou não apresentavam o contorno dos objetos. O algoritmo apresentado utilizou o filtro de *Sobel*, aplicando tanto na horizontal quanto na vertical, seguido do cálculo do gradiente, o qual utilizou o valor do filtro, em seguida foi aplicada a erosão para a remoção de detalhes que não pertenciam à borda, gerando o afinamento da mesma, e posteriormente foi feita a dilatação para expandir as linhas afinadas pela erosão. A imagem passou pelo processo de suavização, onde foram encontrados os máximos regionais, em seguida foi binarizada, aplicando posteriormente a transformada da distância e por fim a transformada de *Watershed*. No entanto o resultado da segmentação não foi significativo, pois a maioria dos pontos encontrados não pertenciam ao contorno, as linhas apresentaram não deram a idéia de circularidade dos objetos, mas apareceram de forma contínua, porém não houve o detalhamento preciso e em algumas imagens houve o comprometimento da borda, pois alguns espaços ficaram totalmente preenchidos, aparecendo em branco, como se fosse a borda da imagem.

O último operador, para extração da borda, utilizado foi o *Zero Crossing*, o qual o contorno apresentou um pouco impreciso, ou seja, faltou alguns detalhes, pois o operador não busca o extremo detalhamento, além de surgirem algumas linhas próximas ao contorno e que não fazem parte dele.

7.3 Resultado da Análise dos Dados

Foram entrevistadas 100 pessoas com o objetivo de verificar, com visões diferentes, qual das técnicas aplicadas realiza a melhor segmentação para imagens específicas.

Para isso foram aplicadas as técnicas de segmentação já mencionadas anteriormente, além de verificar quais dos filtros de melhoria provocaria um resultado positivo na remoção de ruídos pertencentes à imagem. O filtro da mediana trouxe

bons resultados com a sua aplicação, em que a segmentação com a imagem original ficou muito próxima à com utilização do filtro. Os filtros passa-alta e de equalização foram descartados por promover a adição de ruídos na imagem original e isto influenciou de maneira significativa no resultado final, porém na aplicação do algoritmo de Crescimento de Região obteve-se melhor resultado e contorno mais expressivo com o filtro passa-alta em relação ao da mediana, que neste algoritmo foi descartado por não apresentar bons resultados.

A Tabela 1 apresenta os dados coletados de maneira tabulada, onde o *Microsoft Excel* realizou de maneira automática a contagem de pessoas que escolheram determinada técnica de segmentação.

Tabela 1 – Tabulação dos dados coletados com o questionário

Técnicas	Av. Paulista	Masp	Lena	Dumont	Dente Horizontal	Dente Vertical	Microlobulada	Espiculada
Original + Canny	21	29	12	3	43	36	9	16
Original + Region Gowing	2	1	0	0	0	1	4	0
Original + Laplacian	4	7	7	21	1	2	2	10
Original + Prewitt	0	0	1	6	0	2	11	8
Original + Roberts	0	0	2	2	1	3	0	0
Original + Sobel	3	0	0	2	1	0	7	3
Original + SOM	2	3	2	0	0	0	10	5
Original + Split and Merge	0	0	8	2	2	6	0	0
Original + Watershed	0	0	1	0	0	2	0	0
Original + Zero Crossing	1	8	10	13	1	2	1	3
Mediana + Canny	6	15	5	3	41	32	22	26
Passa-Alta + Region Growing	35	25	6	0	0	2	5	6
Mediana + Laplacian	1	5	2	13	0	0	2	2
Mediana + Prewitt	0	0	1	6	1	0	3	1
Mediana + Roberts	1	0	0	0	1	2	4	0
Mediana + Sobel	1	0	2	5	1	0	9	4
Mediana + SOM	13	0	1	0	2	0	10	9
Mediana + Split and Merge	8	0	25	7	3	4	0	0
Mediana + Watershed	0	0	2	2	2	5	0	0
Mediana + Zero Crossing	2	6	13	15	0	1	1	7
Mais Respondidas	35	29	25	21	43	36	22	26

O Gráfico 7.1 apresenta o gráfico referente à imagem da Av. Paulista de São José do Rio Preto, representando a relação de quantidade pessoas pesquisadas pela técnica de segmentação escolhida.

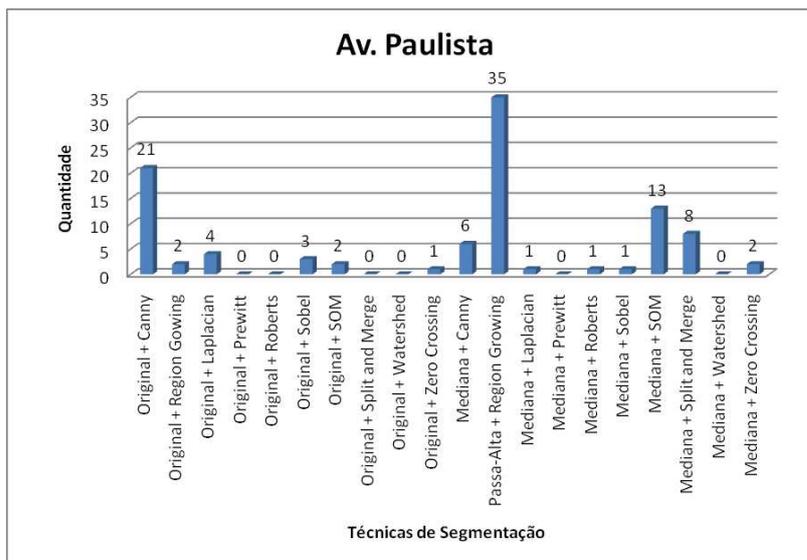


Gráfico 7.1 – Resultado dos Testes de Segmentação da Imagem da Av. Paulista

Com base no gráfico apresentado pode-se concluir que a técnica escolhida pela maioria das pessoas foi com a aplicação do filtro passa-alta seguido do algoritmo de Crescimento de Região, onde 35% escolheu este algoritmo.

Esta imagem apresentou dificuldade na resposta por possuir um tamanho grande, e no questionário ela não pode ficar no tamanho original, além de possuir uma enorme quantidade de detalhes.

Já em relação a imagem do Masp, a técnica escolhida por 29% das pessoas que fizeram parte desta pesquisa foi aplicando o operador *Canny* sobre a imagem original, como demonstrado no Gráfico 7.2

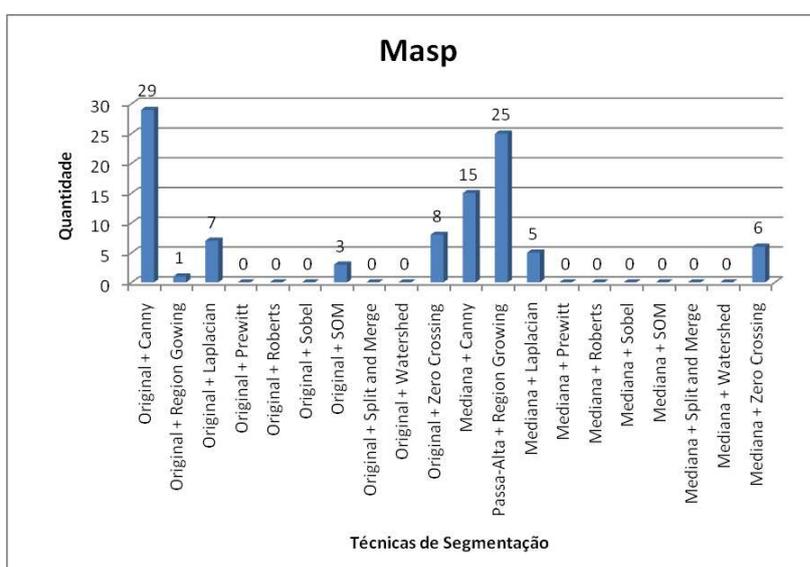


Gráfico 7.2 – Resultado dos Testes de Segmentação da Imagem do Masp

O resultado ficou muito próximo ao algoritmo de Crescimento de Região seguido do filtro passa-alta, pois os dois resultados foram aceitáveis, mas o algoritmo de *Canny* se tornou mais fiel à borda em relação ao Crescimento de Região, que ressaltou uma maior quantidade de detalhes.

Na imagem da Lena o melhor resultado obtido foi aplicando-se o filtro da mediana seguido da segmentação por *Split and Merge* com 25% das escolhas. O Gráfico 7.3 apresenta este resultado.

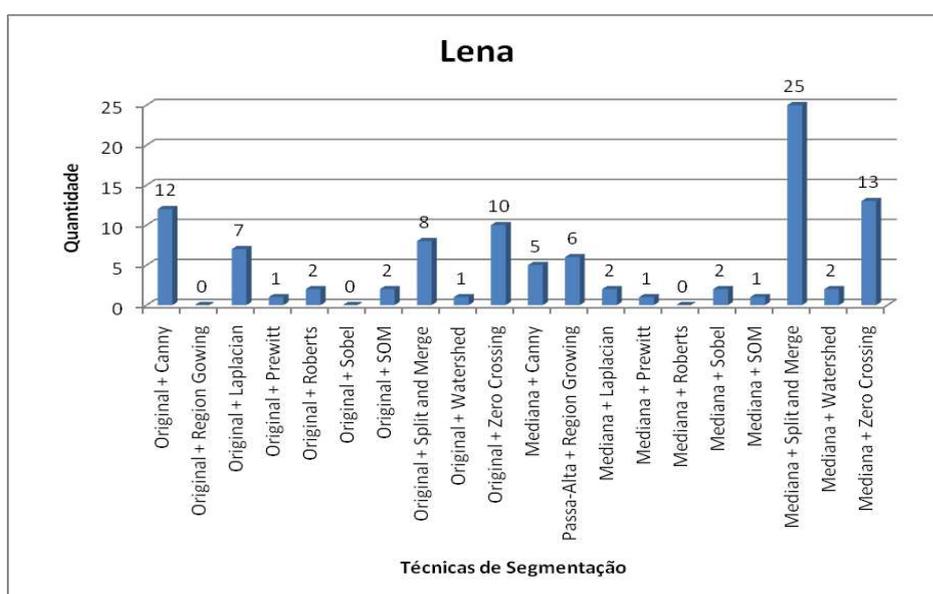


Gráfico 7.3 – Resultado dos Testes de Segmentação da Imagem da Lena

No entanto, esse resultado apresentado não foi bom, pois as linhas de contorno do *Split and Merge* resultaram em um duplicamento próximo, unidas por alguns *pixels*, além aparecer certas descontinuidades e isto comprometeu o bom contorno na imagem da Lena. A forma de segmentação que trouxe as linhas de forma mais contínua e ressaltou o contorno da imagem foi com a aplicação do operador de *Canny* sobre a original ou após a mediana, pois o resultado ficou muito próximo.

A segmentação da imagem de Santos Dumont ficou muito próximos os algoritmos de *laplacian* e *Zero Crossing*, como pode ser observado através do Gráfico 7.4, em que as detecções de contorno mais escolhidas foram ambas, tanto sem o uso dos filtros quanto com sua aplicação. No entanto a de *Laplacian* teve maior escolha, com o índice de 21%, porém ficaram bem divididas, o que refletiu em um índice não muito alto.

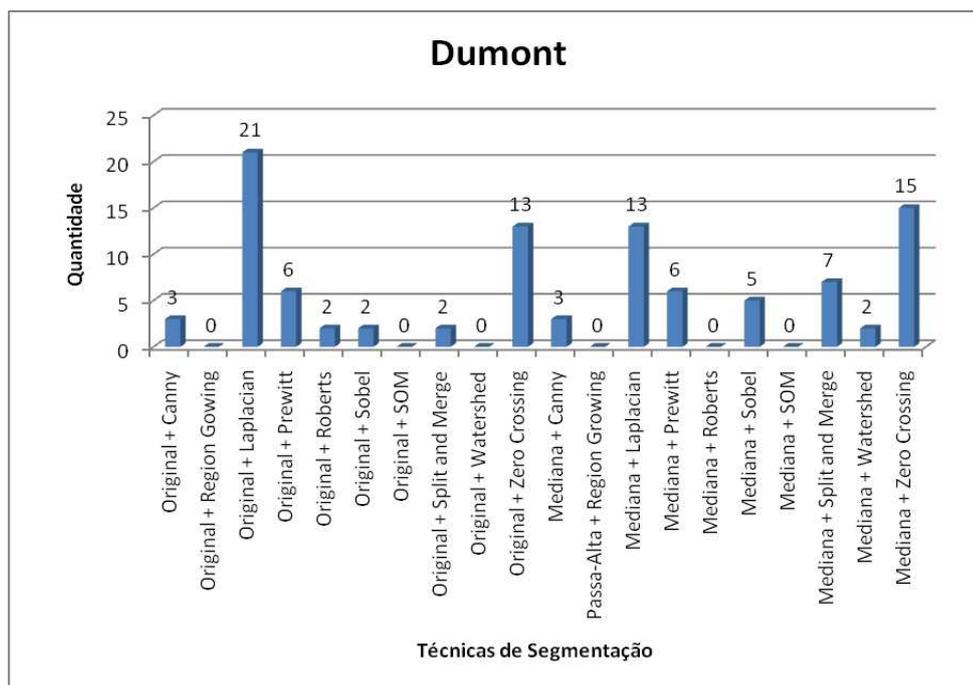


Gráfico 7.4 – Resultado dos Testes de Segmentação da Imagem do Santos Dumont

Nas radiografias dentárias pode ser observado o desconhecimento do tipo das imagens, mesmo que visualizando a imagem original, contudo houve uma certa “unanimidade” na escolha da técnica de segmentação, tanto na imagem radiográfica de dente na vertical quanto na horizontal. O método escolhido foi o operador *Canny*, cujo resultado aplicado sobre a imagem original e após o filtro da mediana ficaram muito próximos, este reflexo podem ser vistos no Gráfico 7.5 com a imagem de dente na horizontal em que obteve-se 43% com a aplicação sobre a imagem original e 41% com a aplicação do filtro da mediana.

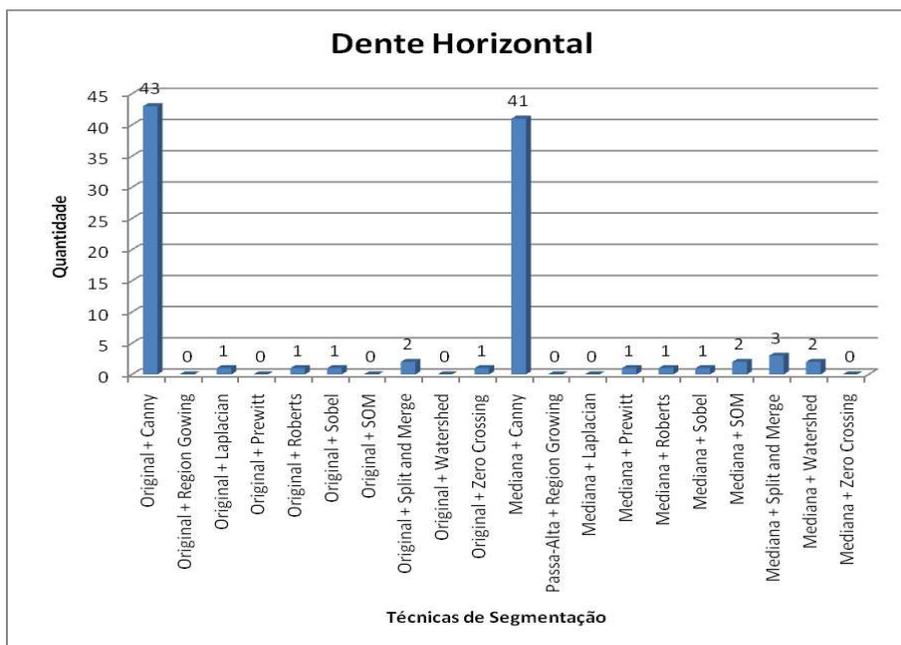


Gráfico 7.5 – Resultado dos Testes de Segmentação da Imagem de Dente na Horizontal

Já no Gráfico 7.6, onde é demonstrado o gráfico da imagem de dente na vertical, o resultado da aplicação foi de 35% do operador *Canny* sobre a original e 32% após a aplicação do filtro da mediana.

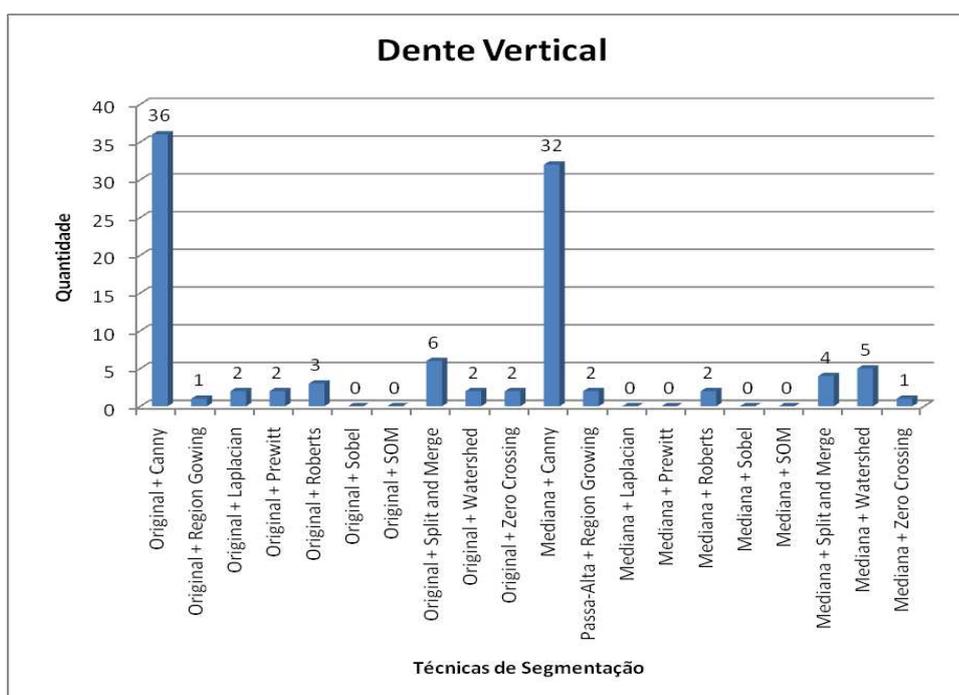


Gráfico 7.6 – Resultado dos Testes de Segmentação da Imagem de Dente na Vertical

As imagens de nódulos mamográficos foram de desconhecimento total dos entrevistados e isto dificultou muito na escolha adequada do método correto de segmentação, gerando uma grande variação na percentagem de escolha. Tanto as imagens de nódulos pertencentes à classe microlobulada quanto à espiculada foram as que tiveram a maior diversidade de escolha. O Gráfico 7.7 comprova essa diversidade em relação a imagem microlobulada, em que a segmentação escolhida pela maioria das pessoas (22%) foi com a aplicação do filtro da mediana seguido pelo detector de *Canny*. No Gráfico 7.8, onde é demonstrado o gráfico pertencente a imagem de câncer espiculada, a técnica escolhida também foi o operador *Canny* após o filtro da mediana, com o total de 26%.

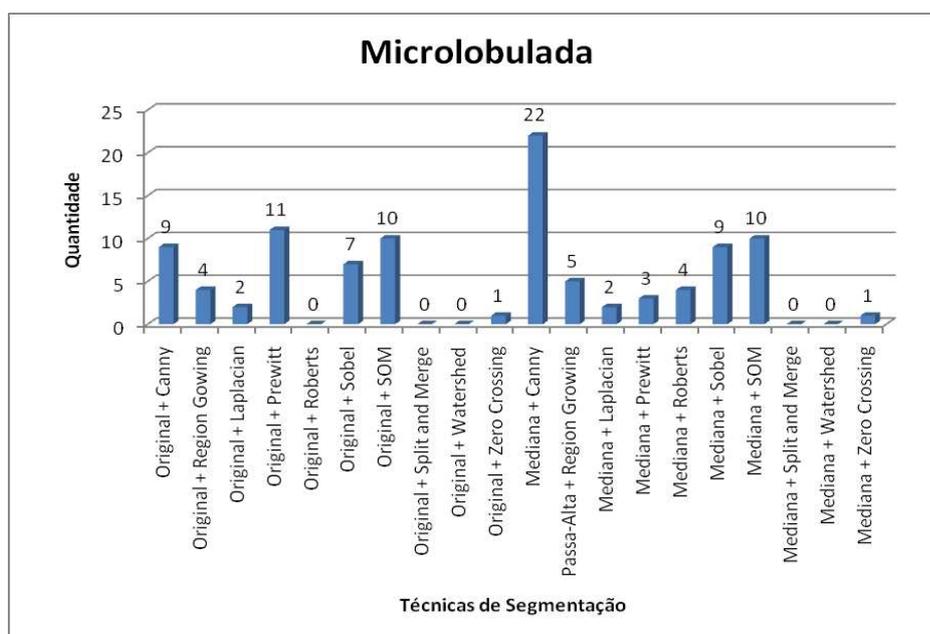


Gráfico 7.7 – Resultado dos Testes de Segmentação da Imagem de Nódulos Mamográficos da Classe Microlobulada

Entretanto, para ambas a imagem, o resultado escolhido não foi expressivo, pois a imagem segmentada pelo operador *Canny* trouxe muitos detalhes que não pertencem ao contorno, onde a técnica mais adequada seria pela rede SOM, que apresentou apenas o contorno do nódulo e não suas ramificações.



Gráfico 7.8 – Resultado dos Testes de Segmentação da Imagem de Nódulos Mamográficos da Classe Espiculada

8 CONCLUSÕES

A utilização da imagem em computação está em processo de crescimento e estão cada vez mais integradas, pois está presente em muitas áreas do conhecimento e utilizada para diversos fins como pôde-se observar neste trabalho. A segmentação também está em um processo de ampliação, pois vem sendo utilizada para reconhecimento de diversas coisas, como caracteres, contornos, auxílio em diagnósticos, entre outros fins.

Este trabalho visou à segmentação por contorno, onde utilizou-se oito imagens com características distintas entre os objetos que as compõe. Para isso foram estudadas as técnicas de segmentação e verificou-se que há muitas além das que foram estudadas. Foram implementados apenas os seguintes algoritmos de segmentação, aos quais foram totalizados em dez, sendo eles, *Canny*, Crescimento de Região, *Laplacian*, *Prewitt*, *Roberts*, *Sobel*, *SOM*, *Split and Merge*, *Watershed* e *Zero Crossing*. Empregaram-se apenas alguns filtros para realizar a melhoria da imagem, pois estes também possuem uma enorme quantidade, e são utilizados para fins específicos.

Pode ser observados que para cada tipo de imagem foi escolhida uma técnica de segmentação diferente, verificando a diferença na aplicação de cada técnica sobre cada grupo de imagem. A rede neural, por exemplo, apresentou bom resultado sobre as imagens de nódulos mamográficos, já em outros tipos de imagens obteve-se melhor resultado com a aplicação de técnicas de processamento de imagens, com isso pode-se concluir que não é por ser uma RNA que a segmentação será boa para qualquer imagem.

Buscou-se obter uma boa segmentação para todos os tipos de imagens selecionadas, pois houve uma grande dificuldade de escolher uma segmentação automática para estas imagens. Esta diferença na segmentação de imagens com características distintas foi nota no algoritmo de Crescimento de Região, em que foi definido um valor padrão de semente e de limiar, onde o limiar foi representado pela média dos níveis de cinza de cada imagem, já a semente escolhida foi o maior valor de nível de cinza em cada imagem. No entanto, pode ser observado que este

algoritmo encontrou melhores resultados de segmentação, só que não seguia um padrão, ficando específico para cada tipo de imagem, pois os valores foram escolhidos aleatoriamente até obter um bom resultado visualmente.

Gato *et al.* (2001) revela que os métodos totalmente automatizados ainda não são satisfatórios, pois geram bons resultados somente quando aplicados à imagens controladas, uma alternativa é procurar desenvolver métodos semi-automáticos, este é realizado através da interação do operador com o sistema, ou seja, o operador é responsável por tomar decisões.

A aplicação do questionário apresentou resultados inesperados, pois muitas técnicas escolhidas, aparentemente, demonstraram-se ruins, revelando assim a diferenciação do conceito de contorno para cada pessoa.

A escolha da técnica adequada para cada tipo de imagem também foi dificultada, pois algumas delas ficaram muito próximas umas das outras.

Observou-se ainda, com a aplicação do questionário a dificuldade de especificação do contorno, pois para cada pessoa a definição de contorno varia, podendo ser visualizada na tabulação dos dados, onde cada pessoa apresentou resultados muito distantes dos que haviam sido esperados.

Muitas das técnicas de segmentação foram escolhidas pela quantidade de detalhamento e não pelo contorno em si, pois muitas desses métodos trouxeram objetos que não pertencem ao contorno, que foram detectados por causa da transição dos níveis de cinza.

Solana (2005) apresenta a borda como variações de intensidades complexas que ocorrem em uma região e estas variações são geralmente chamadas de textura, no entanto contorno é uma linha fechada formada pelas bordas de um objeto dentro de uma imagem. A Figura 8.1 demonstra essa diferença entre textura e contorno, em que o operador de *Canny* traz o máximo detalhamento do nóculo já a segmentação pela rede SOM apenas o contorno.

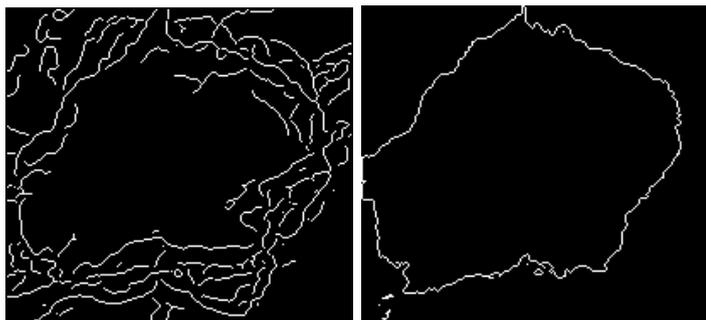


Figura 8.1 - Segmentação da imagem Microlobulada pelo operador *Canny* e a rede neural SOM

8.1 Trabalhos Futuros

A continuidade deste trabalho pode aprofundar as pesquisas no sentido das técnicas de segmentação envolvidas, para isso apresentam-se algumas sugestões:

- a) melhorar os algoritmos de segmentação por contorno que foram desenvolvidos, incluindo tanto os de processamento de imagens quanto ao de redes neurais artificiais, com a rede SOM, adaptando-os a um tipo específico de imagem.
- b) estudar e desenvolver outros algoritmos que visam a extração do contorno.

REFERÊNCIAS

ARTERO, A. O.; TOMMASELLI, A. M. G. Um método para a Conexão e aproximação poligonal de elementos de borda em imagens digitais. **Boletim de Ciências Geodésicas**, Curitiba, v. 8, n. 1, p.71-94, 2002. Disponível em: <<http://ojs.c3sl.ufpr.br/ojs2/index.php/bcg/article/viewPDFInterstitial/1415/1169>>. Acesso em: 16 maio 2009.

AZEVEDO, F. M.; BRASIL, L. M.; OLIVEIRA, R. C. L.; **Redes neurais**: com aplicações em controles e em sistemas especialistas. Florianópolis: Bookstore, 2000.

BOTELHO, M. F. **Modelagem tridimensional de edificações usando dados do sistema laser scanner e imagem orbital de alta resolução espacial**. 2007, 129f. Tese (Doutorado em Ciências Geodésicas) – Universidade Federal do Paraná, Curitiba. Disponível em: <http://dspace.c3sl.ufpr.br/dspace/bitstream/1884/13905/1/TESEDOUTORADO_Mosar_ComParecer.pdf>. Acesso em: 25 maio 2009.

BRAGA, A. de P.; CARVALHO, A. C. P. de L. F.; LUDEMIR, T. B. **Redes neurais artificiais**: Teoria e aplicações. Rio de Janeiro: Livros Técnicos e Científicos, 2000.

CARVALHO A. A de. **Fundamentação teórica para processamento digital de imagens**. 2003, 18f. Referencial Teórico para Monografia (Bacharelado em Ciência da Computação) – Universidade Federal de Lavras, Lavras. Disponível em: <www.epamig.br/geosolos/MN_GEO/monografia.pdf>. Acesso em: 05 maio 2009.

ESPINDOLA, G. M. de; CÂMARA, G. Ajuste de parâmetros no algoritmo de segmentação de imagens do software e cognition. In: SIMPÓSIO DE SENSORIAMENTO REMOTO. 13., 21-26 abr 2007, Florianópolis. **Anais eletrônicos...** Florianópolis: INPE, 2007. Disponível em: <marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.15.22.12/doc/5739-5744.pdf>. Acesso em 16 maio 2009.

FIALHO, M. de Q. **Extração de padrões da íris para sistemas de reconhecimento**. 2006. 64f. Trabalho de Disciplina (Curso de Engenharia Elétrica) – Faculdade de Engenharia, Pontifícia Universidade Católica do Rio Grande do Sul, Porto Alegre. Disponível em: <http://www.pucrs.br/feng/tcc/eletrica/2006_1_199_trabalho.pdf>. Acesso em: 19 maio 2009.

GATO, H. E. R.; IMAI, N. N.; TOMMASELLI, A. M. G. Uma abordagem semi-automática para extração de feições cartográficas. **Revista Brasileira de**

Cartografia, Nº 53, p. 16-28, dezembro 2001. Disponível em: < http://www.rbc.ufrj.br/_pdf_53_2001/53_02.pdf>. Acesso em: 03 nov 2009.

GALVANIN, E. A. dos S.; POZ, A. P. D.; SOUZA, A. D. P. de. Extração de contorno de telhados a partir de um modelo digital de elevação. **II Simpósio Brasileiro de Geomática**, Presidente Prudente, 24-27 de julho de 2007. Disponível em: <http://www4.fct.unesp.br/pos/cartografia/docs/anaiseventos/galvanin_extrac_contornos_telhados_sbg_cbcg_2007.PDF>. Acesso em: 01 nov 2009.

GONZALEZ, R. C. WOODS, R. E. **Processamento de imagens digitais**. São Paulo: Edgard Blücher, 2000.

HAYKIN, S. **Redes neurais: Princípios e Práticas**. 2. ed. Porto Alegre: Bookman, 2001.

INÁCIO, L. M. C. **Sistema de Informação e Processamento para Radiologia Odontológica**. 2007. 148f. Dissertação (Mestrado em Engenharia Eletrônica e Telecomunicações) – Universidade de Aveiro, Aveiro – Portugal. Disponível em <<http://biblioteca.sinbad.ua.pt/teses/2008000951>>. Acessado em 03 nov. 2009.

LIMA, J. C. B. O.; **Análise de algoritmos de segmentação de textos de imagens de documentos históricos**. 2006. 75f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia da Computação) – Escola Politécnica de Pernambuco, Recife. Disponível em: <dsc.upe.br/~tcc/20062/TCCFinal_Juliane.pdf>. Acesso em: 28 abr 2009.

MARQUES FILHO, O.; VIEIRA NETO, H. **Processamento digital de imagens**. Rio de Janeiro: Brasport, 1999.

MÁTTAR NETO, J. A.; **Metodologia científica na era da informática**. São Paulo: Saraiva, 2002.

MOSSMANN, J. B. **Princípio e prática da análise de imagens médicas**. 2006. 74f. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) – Centro Universitário Feevale, Novo Hamburgo. Disponível em: <<http://ead.feevale.br/tc/files/759.pdf>>. Acesso em 19 maio 2009.

NEVES, S. C. M. **Estudo e implementação de técnicas de segmentação de imagens**. Revista Virtual de Iniciação Acadêmica da UFPA, v. 1, n. 2, p.1-11, jul 2001. Disponível em: <http://www2.ufpa.br/rcientifica/ed_anteriores/pdf/ed_02_scmn.pdf>. Acesso em: 15 abr 2009.

NIXON, M. S.; AGUADO, A. S. **Feature extraction and image processing**. Newnes: Oxford, 2002.

NOGUEROL, L. **Sistema de informação como apoio ao diagnóstico em parasitologia**. 2008. 45f. Trabalho de Conclusão de Curso (Sistemas de Informação) – Instituto de Ciências Exatas e Tecnológicas, Novo Hamburgo. Disponível em: <http://tconline.feevale.br/tc/files/0002_1511.pdf>. Acesso em: 15 out. 2009.

PRATT, W. K. **Digital image processing**: piks Scientific inside. 4. ed. New Jearsey: Wiley, 2007.

RIBEIRO, P. B.; **Classificação por análise de contornos de nódulos mamários utilizando redes neurais artificiais**. 2006. 152f. Dissertação (Mestrado em Engenharia Elétrica) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

RUEDA, R. **Ferramenta para segmentação interativa de imagens**. 2007, 23f. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) – Universidade de São Paulo, São Paulo. Disponível em: <<http://www.linux.ime.usp.br/~rrueda/mac499/monografia.pdf>>. Acesso em 29 maio 2009.

SANTOS, V. T. **Segmentação de imagens mamográficas para detecção de nódulos em mamas densas**. 2002, 112f. Dissertação (Mestrado em Engenharia Elétrica) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/18/18133/tde-16042003-183808/>>. Acesso em: 09 abr 2009.

SILVA, A. de O. **Transformada de watershed para a segmentação de imagens médicas da região pélvica**. 2003. 120f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Tecnologia, Universidade de Brasília, Brasília. Disponível em: <http://www.kn.ene.unb.br/~a0177521/textoFinal_1101_tarde.pdf>. Acesso em: 29 abr 2009.

SILVA, A. C.; CARVALHO, P. C. P. Sistema de análise de nódulo pulmonar. II **Workshop de Informática aplicada à Saúde – CBComp 2002**. Disponível em: <<http://www.visgrafimpa.br/Projects/vismed/lung/doc1/CBComp2002.pdf>>. Acesso em: 29 out 2009.

SIMÕES, A. da S. **Aprendizado não-supervisionado em redes neurais pulsadas de base radial**. 2006, 159f. Tese (Doutorado em Engenharia Elétrica) – Escola Politécnica, Universidade de São Paulo. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/3/3141/tde-15092006-153353/>>. Acesso em 02 jun 2009.

SOLANA, C. D. O. **Reconstrução digital de documentos por aproximação poligonal**. 2005, 88f. Dissertação (Mestrado em Informática Aplicada) – Universidade Católica do Paraná, Curitiba. Disponível em: <http://www.biblioteca.pucpr.br/tede//tde_busca/arquivo.php?codArquivo=337>. Acesso em: 05 nov 2009.

SOUZA, T.; CORREA, S.; Estudo das técnicas de realce de imagens digitais e suas aplicações. In: CONGRESSO DE PESQUISA E INOVAÇÃO DA REDE NORTE E NORDESTE DE EDUCAÇÃO TECNOLÓGICA, 2., 2007, Paraíba. **Anais eletrônicos...** Paraíba, 2007. Disponível em <http://www.redenet.edu.br/publicacoes/arquivos/20080127_131848_INFO-022.pdf> Acesso em: 16 maio 2009.

TOMITA, N. S. **Programação automática de máquinas morfológicas binárias baseada em aprendizado PAC**. 1996, 176f. Dissertação (Mestrado em Matemática Aplicada) – Universidade de São Paulo. São Paulo. Disponível em: <http://www.vision.ime.usp.br/~jb/thesis/nina_master.pdf>. Acesso em: 21 maio 2009.

TORRES, G. V. **Nova abordagem para o processamento e análise de imagens topográficas da córnea humana**. 2006, 98.f Dissertação (Mestrado em Ciências) – Faculdade de Filosofia, Ciências e Letras, Universidade de São Paulo, Ribeirão Preto. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/59/59135/tde-03032008-090325/>>. Acesso em: 17 maio 2009.

VALE, G. M. do; POZ, A. P. D. Processo de detecção de bordas de canny. **Boletim de Ciências Geodésicas**, Curitiba, v. 8, n. 2, p.67-78, 2002. Disponível em: <<http://ojs.c3sl.ufpr.br/ojs2/index.php/bcg/article/view/1421/1175>>. Acesso em: 07 maio 2009.

APÊNDICES

APÊNDICE A – IMAGENS DE PRÉDIOS

APÊNDICE B – IMAGENS DO MASP

APÊNDICE C – IMAGENS DA LENA

APÊNDICE D – IMAGENS DO SANTOS DUMONT

APÊNDICE E – IMAGENS DE RADIOGRAFIAS DENTÁRIAS NA HORIZONTAL

APÊNDICE F – IMAGENS DE RADIOGRAFIAS DENTÁRIAS NA VERTICAL

APÊNDICE G – IMAGENS DE NÓDULOS MAMOGRÁFICOS DA CLASSE
MICROLOBULADA

APÊNDICE H – IMAGENS DE NÓDULOS MAMOGRÁFICOS DA CLASSE
ESPICULADA

APÊNDICE A – IMAGENS DE PRÉDIOS

A.1 – IMAGENS ORIGINAIS SEGUIDAS DE FILTROS DE MELHORIA



a) Original



b) Mediana



d) Equalizada



e) Passa-Alta

A.2 – IMAGENS ORIGINAIS APÓS A APLICAÇÃO DAS TÉCNICAS DE SEGMENTAÇÃO



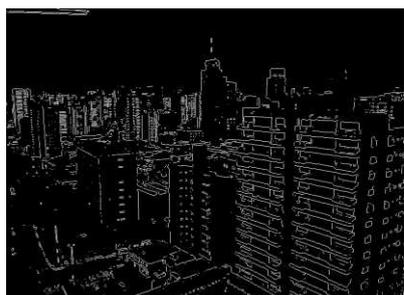
a) Canny - Cinza



b) Region Growing - Cinza



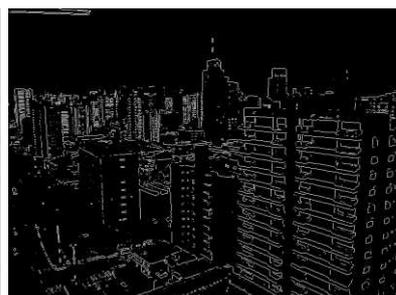
c) Laplacian - Cinza



d) Prewitt



e) Roberts



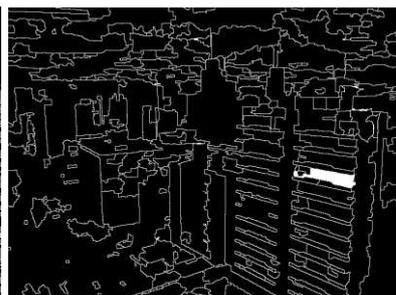
f) Sobel



g) SOM



h) Split and Merge



i) Watershed



j) Zero Cross

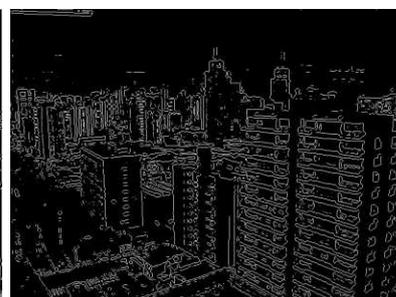
A.3 – IMAGENS COM O FILTRO DA MEDIANA SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO



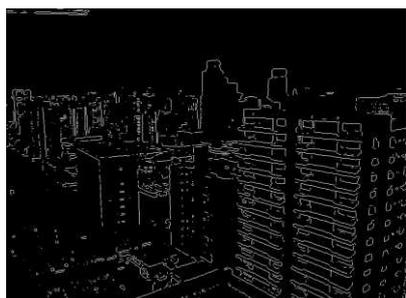
a) Canny



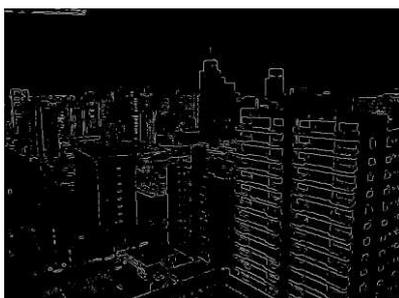
b) Crescimento de Região



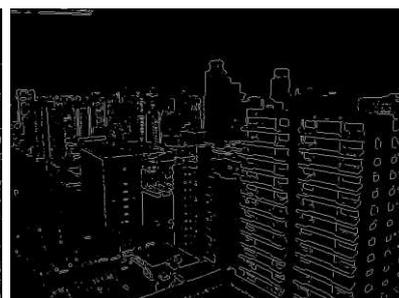
c) Laplacian



d) Prewitt



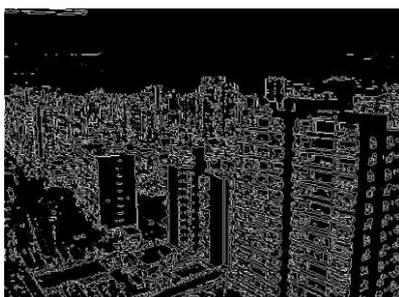
e) Roberts



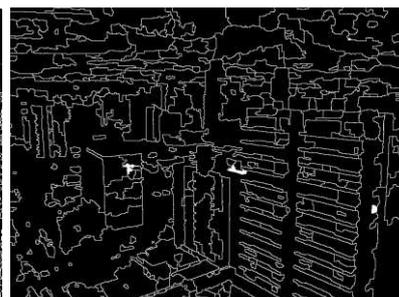
f) Sobel



g) SOM



h) Split and Merge

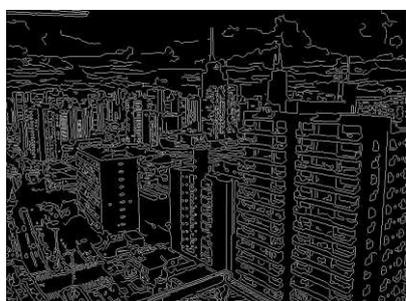


i) Watershed

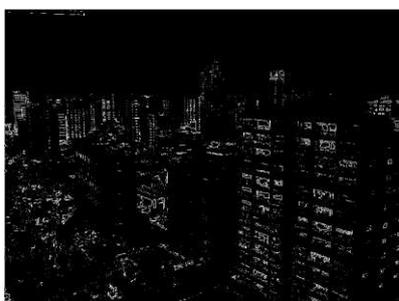


j) Zero Cross

A.4 – IMAGENS EQUALIZADAS SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO



a) Canny



b) Crescimento de Região



c) Laplacian



d) Prewitt



e) Roberts



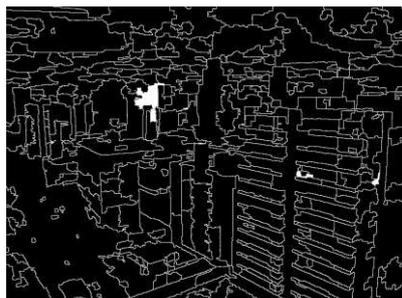
f) Sobel



g) SOM



h) Split and Merge



i) Watershed



j) Zero Cross

A.5– IMAGENS COM O FILTRO PASSA-ALTA SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO



a) Canny



b) Crescimento de Região



c) Laplacian



d) Prewitt



e) Roberts



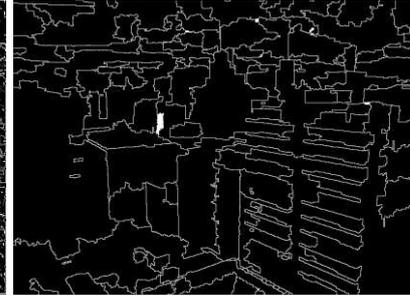
f) Sobel



g) SOM



h) Split and Merge



i) Watershed



j) Zero Cross

APÊNDICE B – IMAGENS DO MASP

B.1 – IMAGENS ORIGINAIS SEGUIDAS DE FILTROS DE MELHORIA



a) Original



b) Mediana



c) Equalizada



d) Passa-Alta

B.2 – IMAGENS ORIGINAIS APÓS A APLICAÇÃO DAS TÉCNICAS DE SEGMENTAÇÃO



a) Canny



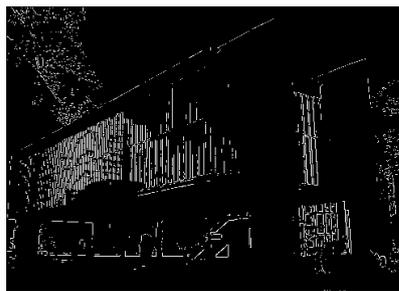
b) Crescimento de Região



c) Laplacian



d) Prewitt



e) Roberts



f) Sobel



g) SOM



h) Split and Merge



i) Watershed



j) Zero Cross

B.3– IMAGENS COM O FILTRO DA MEDIANA SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO



a) Canny



b) Crescimento de Região



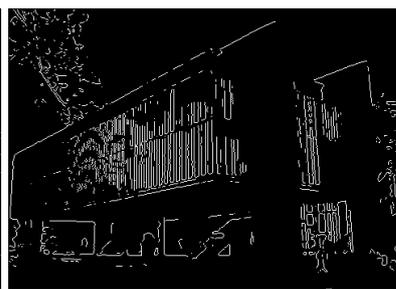
c) Laplacian



d) Prewitt



e) Roberts



f) Sobel



g) SOM



h) Split and Merge



i) Watershed



j) Zero Cross

B.4– IMAGENS EQUALIZADAS SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO



a) Canny



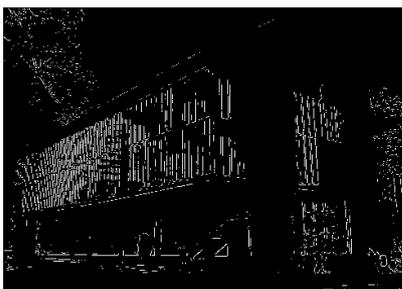
b) Crescimento de Região



c) Laplacian



d) Prewitt



e) Roberts



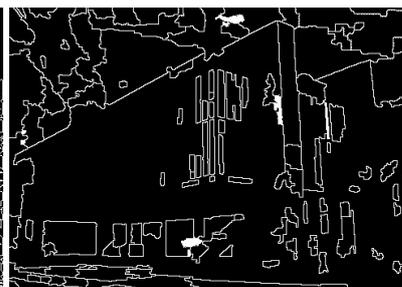
f) Sobel



g) SOM



h) Split and Merge



i) Watershed



j) Zero Cross

B.5– IMAGENS COM O FILTRO PASSA-ALTA SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO



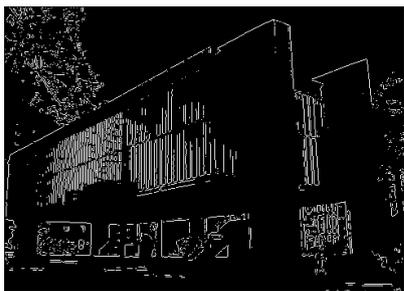
a) Canny



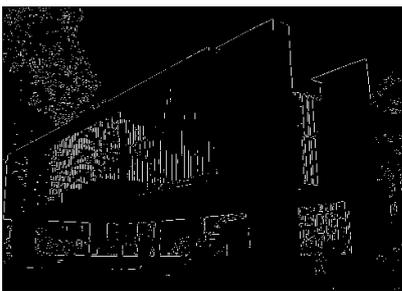
b) Crescimento de Região



c) Laplacian



d) Prewitt



e) Roberts



f) Sobel



g) SOM



h) Split and Merge



i) Watershed



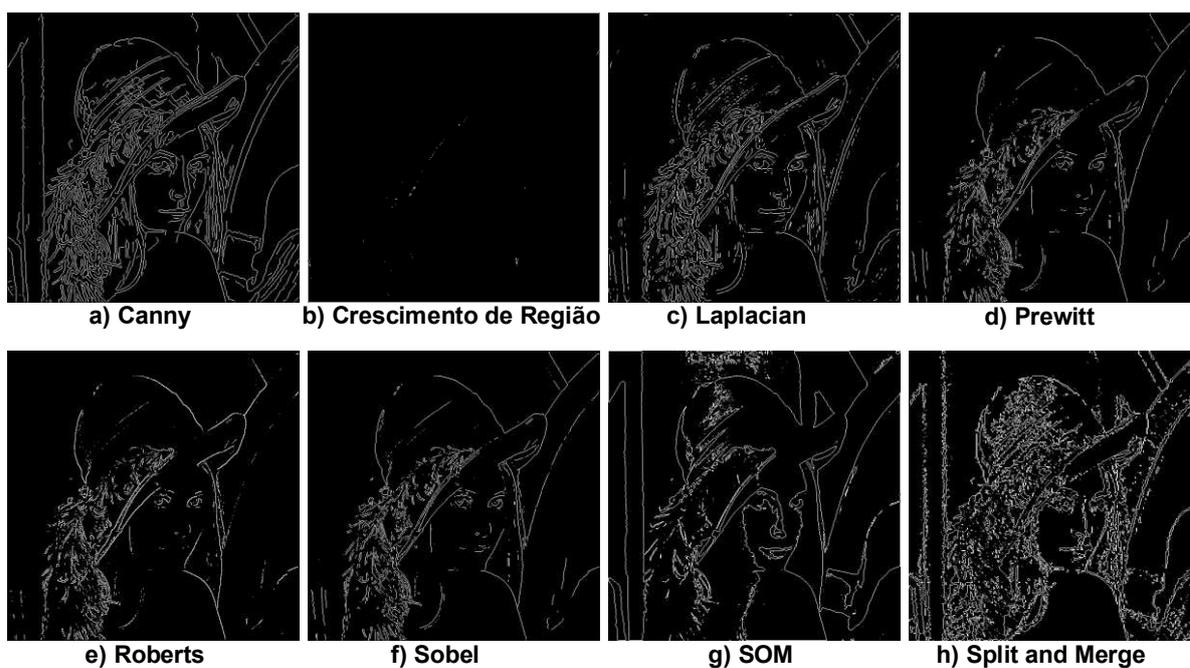
j) Zero Cross

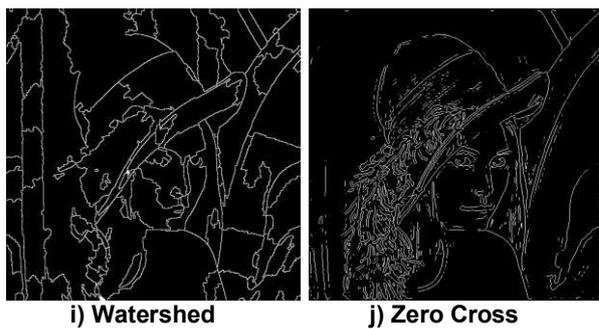
APÊNCIDE C – IMAGENS DA LENA

C.1– IMAGENS ORIGINAIS SEGUIDAS DE FILTROS DE MELHORIA

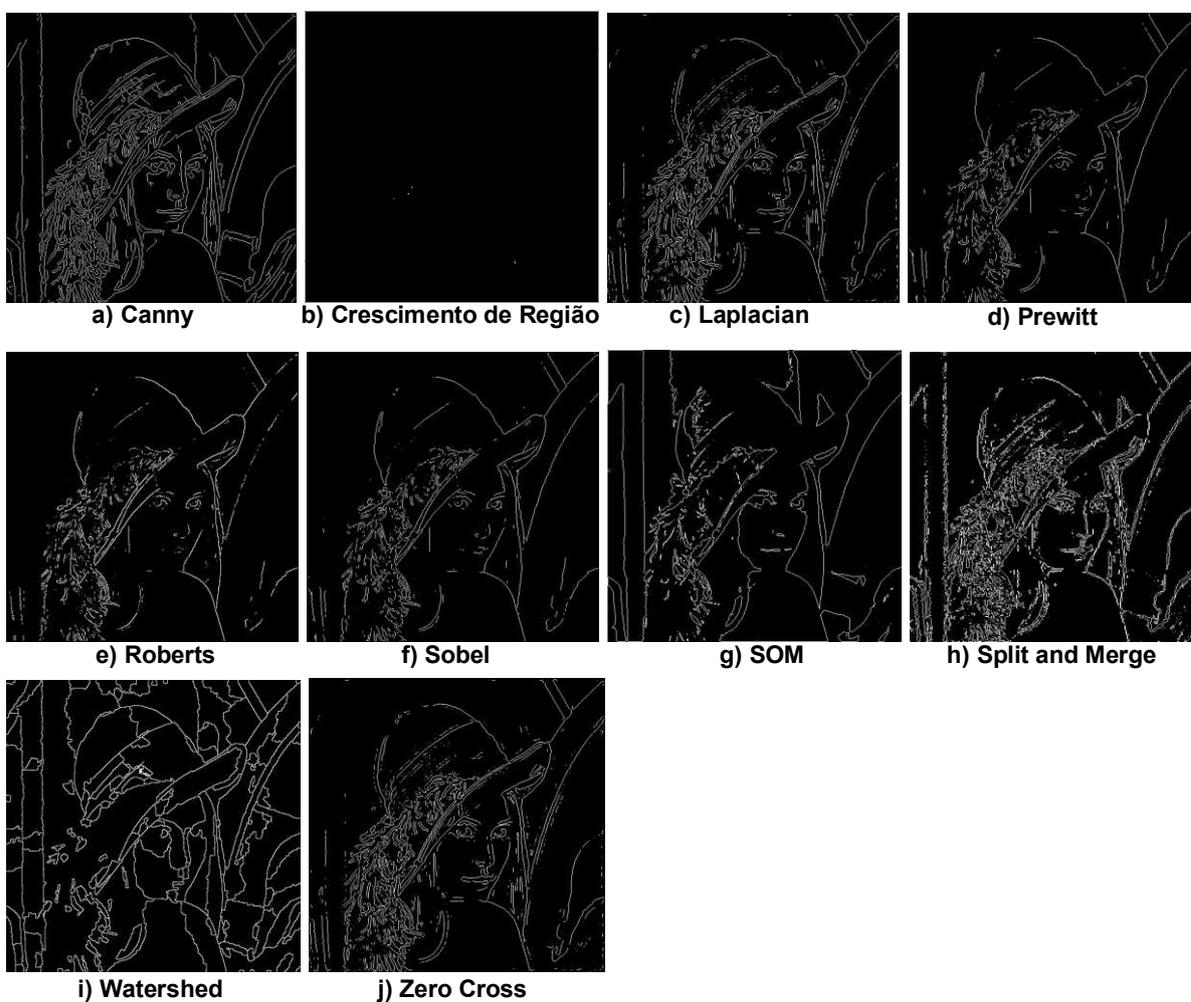


C.2– IMAGENS ORIGINAIS APÓS A APLICAÇÃO DAS TÉCNICAS DE SEGMENTAÇÃO

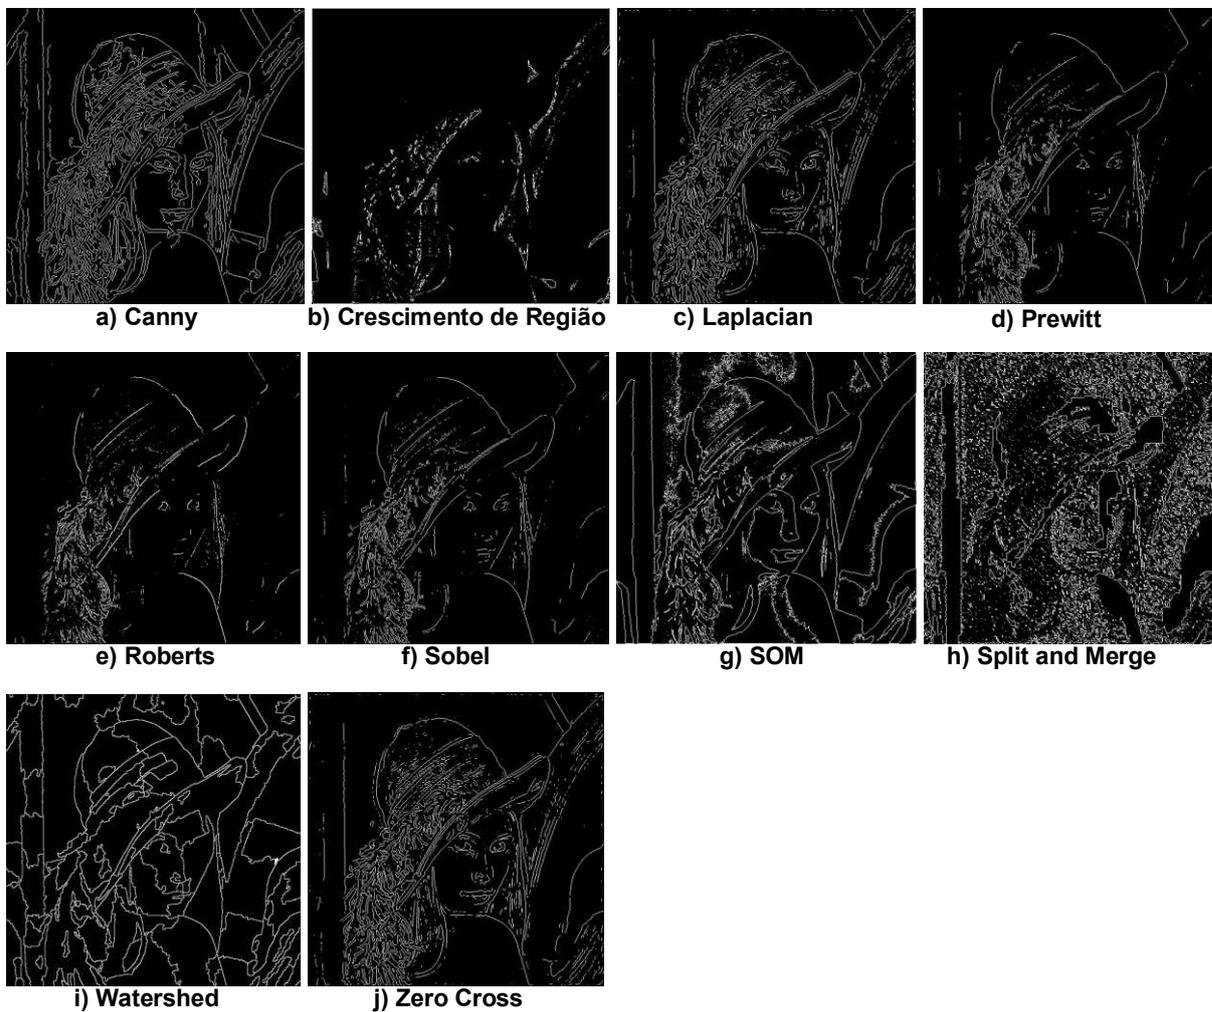




C.3– IMAGENS COM O FILTRO DA MEDIANA SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO



C.4– IMAGENS EQUALIZADAS SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO



C.5– IMAGENS COM O FILTRO PASSA-ALTA SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO





e) Roberts



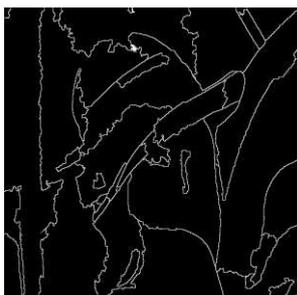
f) Sobel



g) SOM



h) Split and Merge



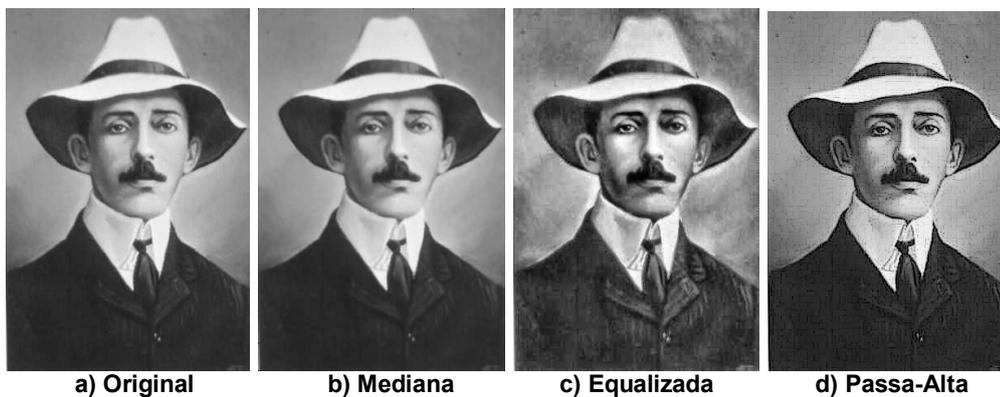
i) Watershed



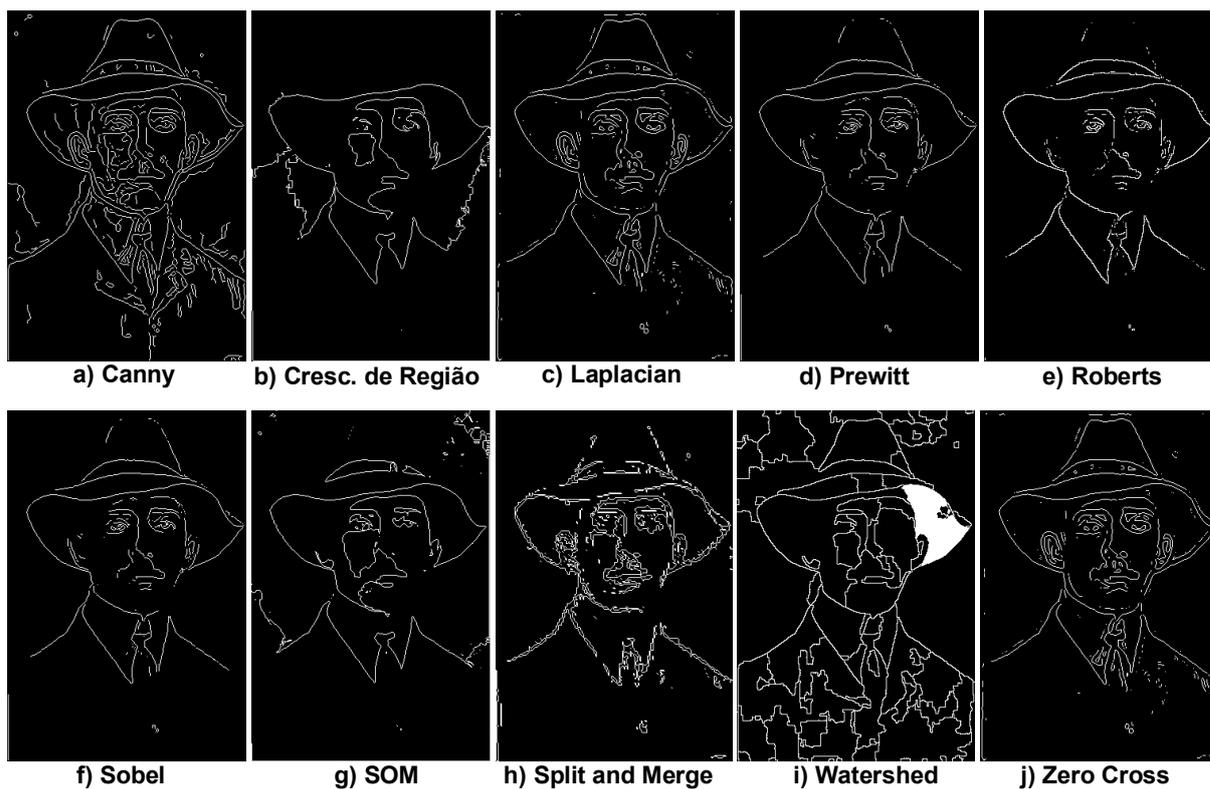
j) Zero Cross

APÊNDICE D – IMAGENS DO SANTOS DUMONT

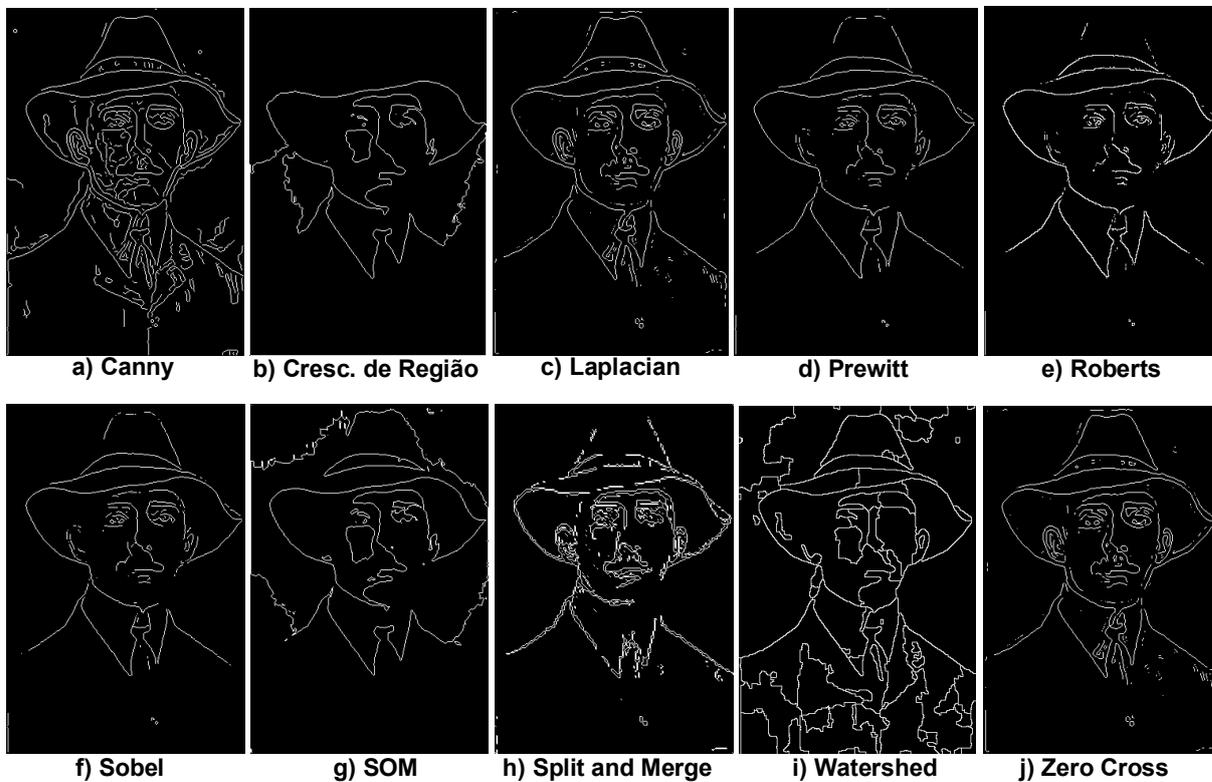
D.1– IMAGENS ORIGINAIS SEGUIDAS DE FILTROS DE MELHORIA



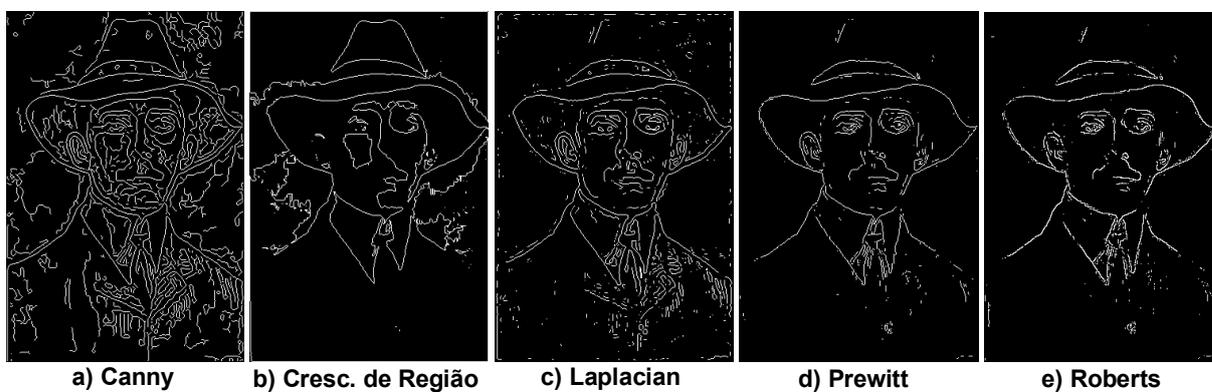
D.2– IMAGENS ORIGINAIS APÓS A APLICAÇÃO DAS TÉCNICAS DE SEGMENTAÇÃO

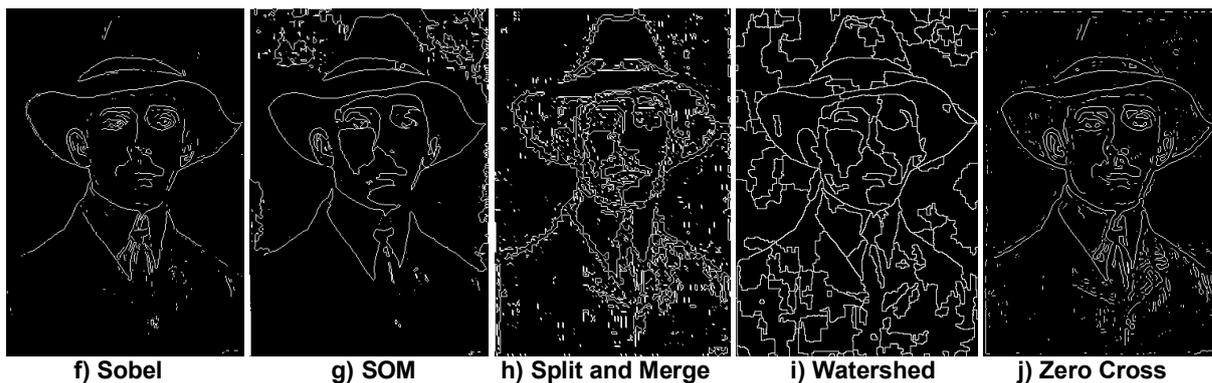


D.3– IMAGENS COM O FILTRO DA MEDIANA SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO



D.4– IMAGENS EQUALIZADAS SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO





f) Sobel

g) SOM

h) Split and Merge

i) Watershed

j) Zero Cross

D.5– IMAGENS COM O FILTRO PASSA-ALTA SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO



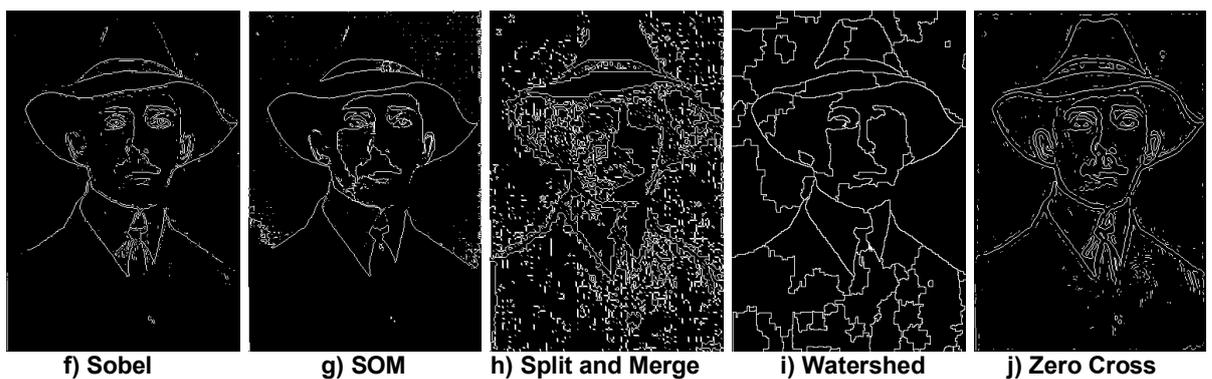
a) Canny

b) Cresc. de Região

c) Laplacian

d) Prewitt

e) Roberts



f) Sobel

g) SOM

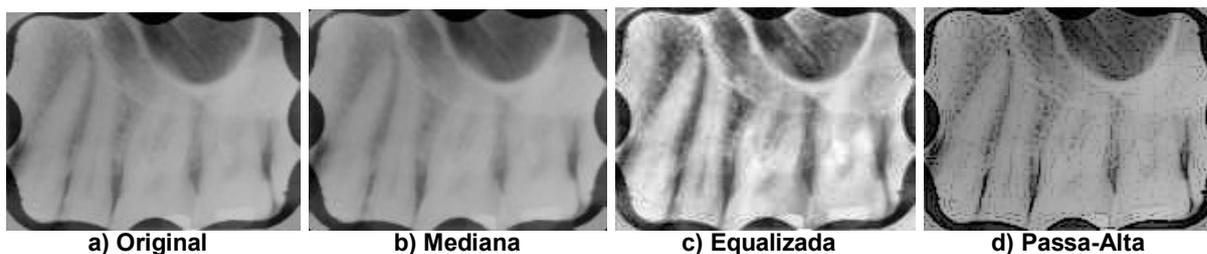
h) Split and Merge

i) Watershed

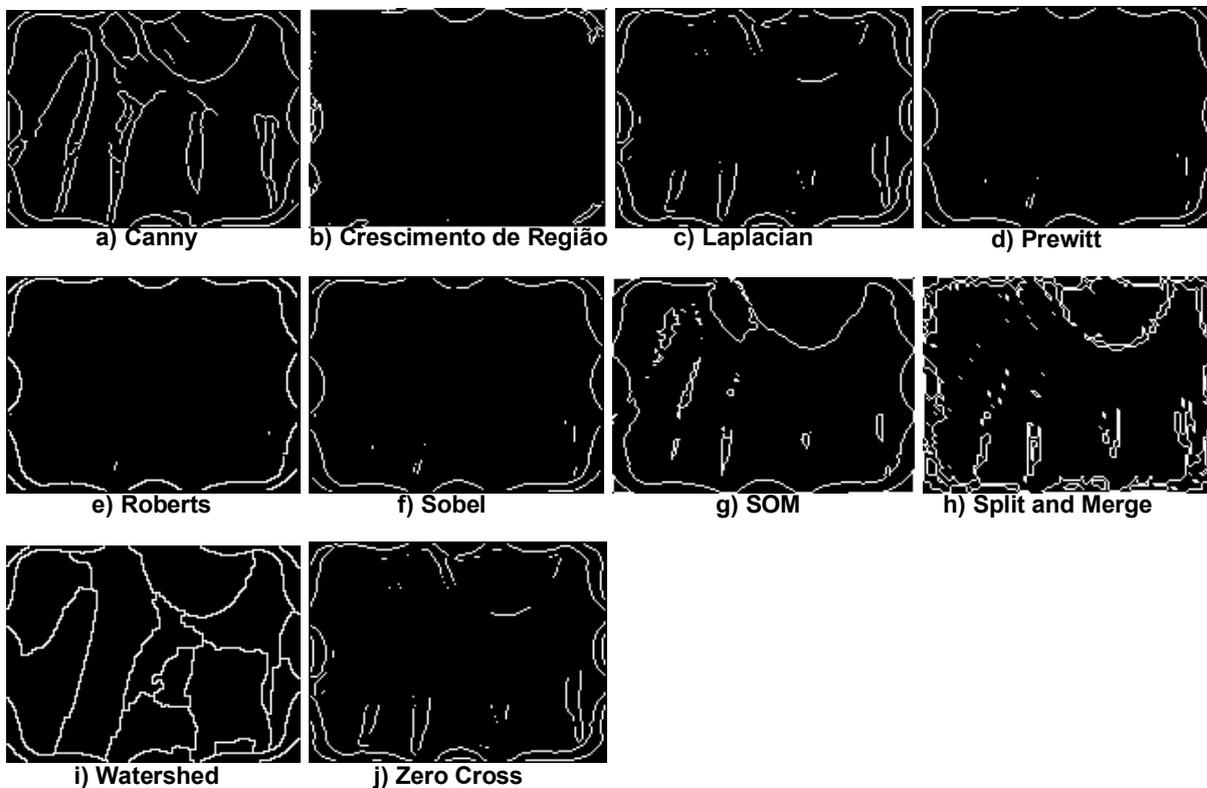
j) Zero Cross

APÊNDICE E – IMAGENS DE RADIOGRAFIAS DENTÁRIAS NA HORIZONTAL

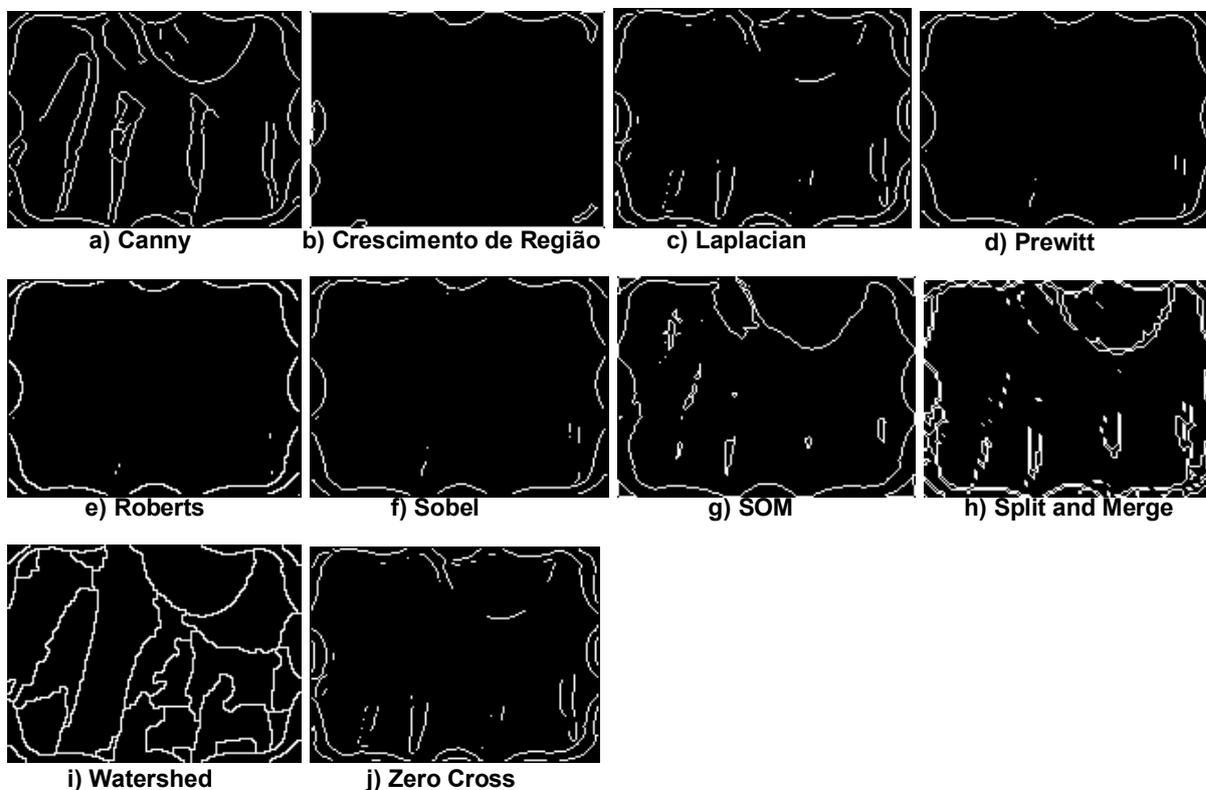
E.1 – IMAGENS ORIGINAIS SEGUIDAS DE FILTROS DE MELHORIA



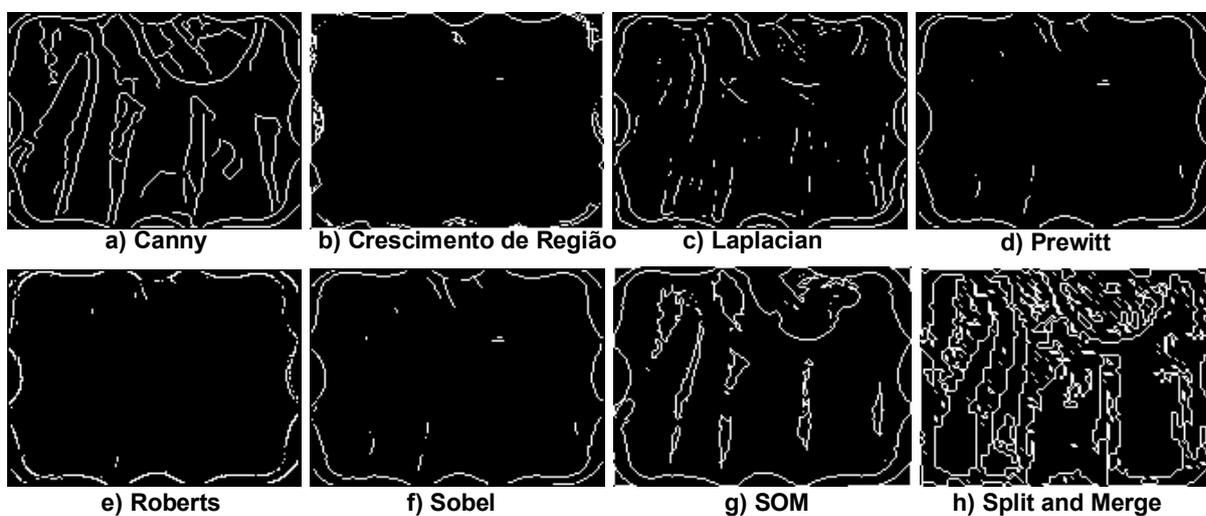
E.2 – IMAGENS ORIGINAIS APÓS A APLICAÇÃO DAS TÉCNICAS DE SEGMENTAÇÃO

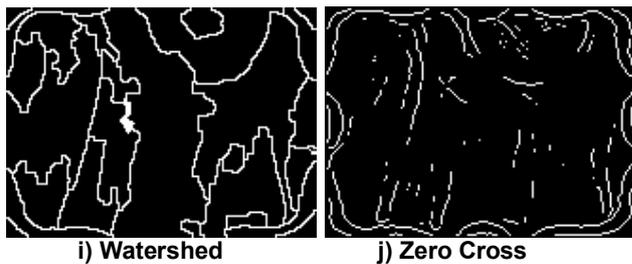


E.3– IMAGENS COM O FILTRO DA MEDIANA SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO

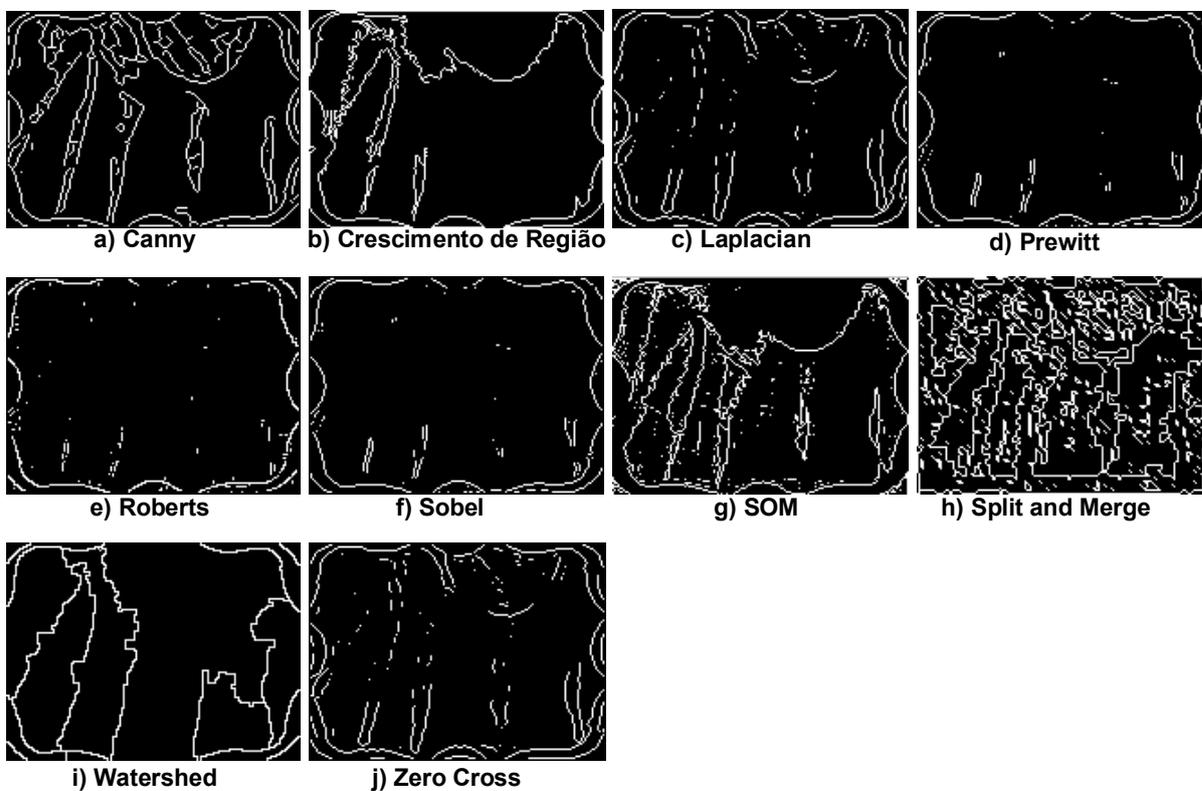


E.4– IMAGENS EQUALIZADAS SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO



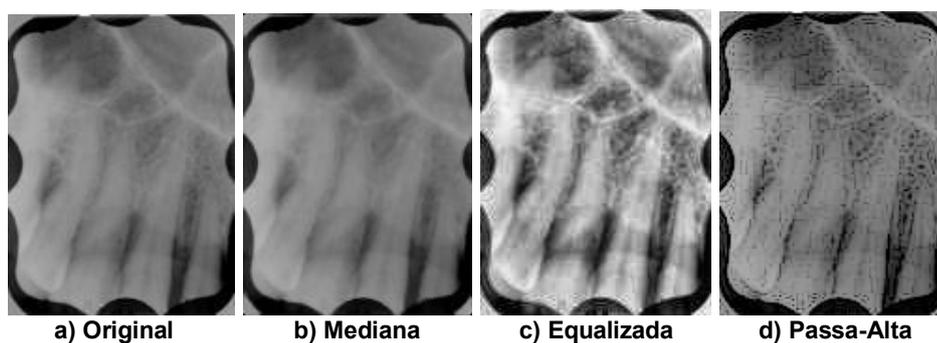


E.5– IMAGENS COM O FILTRO PASSA-ALTA SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO

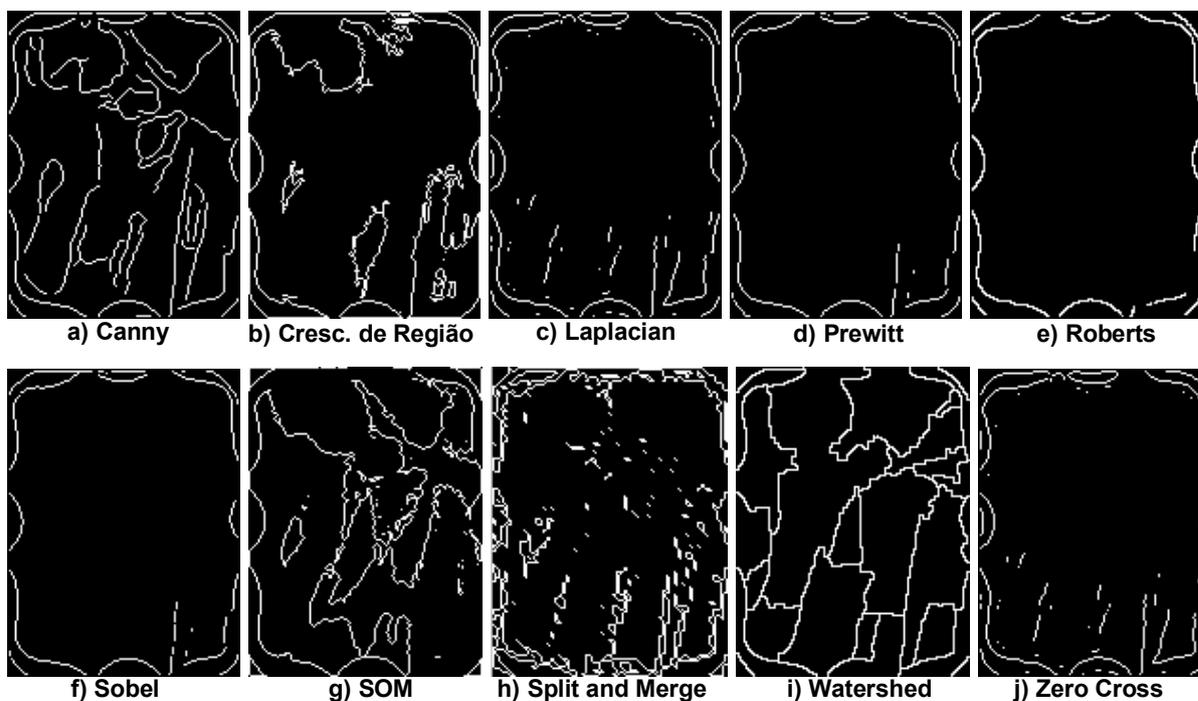


APÊNDICE F – IMAGENS DE RADIOGRAFIAS DENTÁRIAS NA VERTICAL

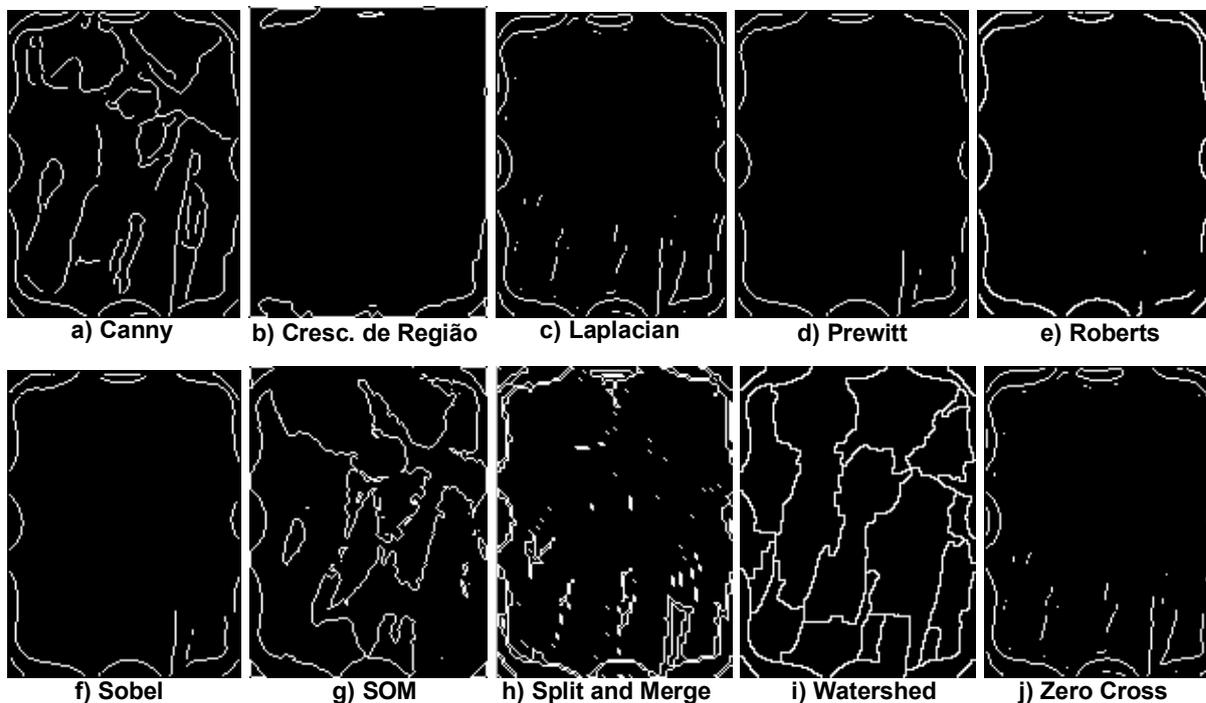
F.1 – IMAGENS ORIGINAIS SEGUIDAS DE FILTROS DE MELHORIA



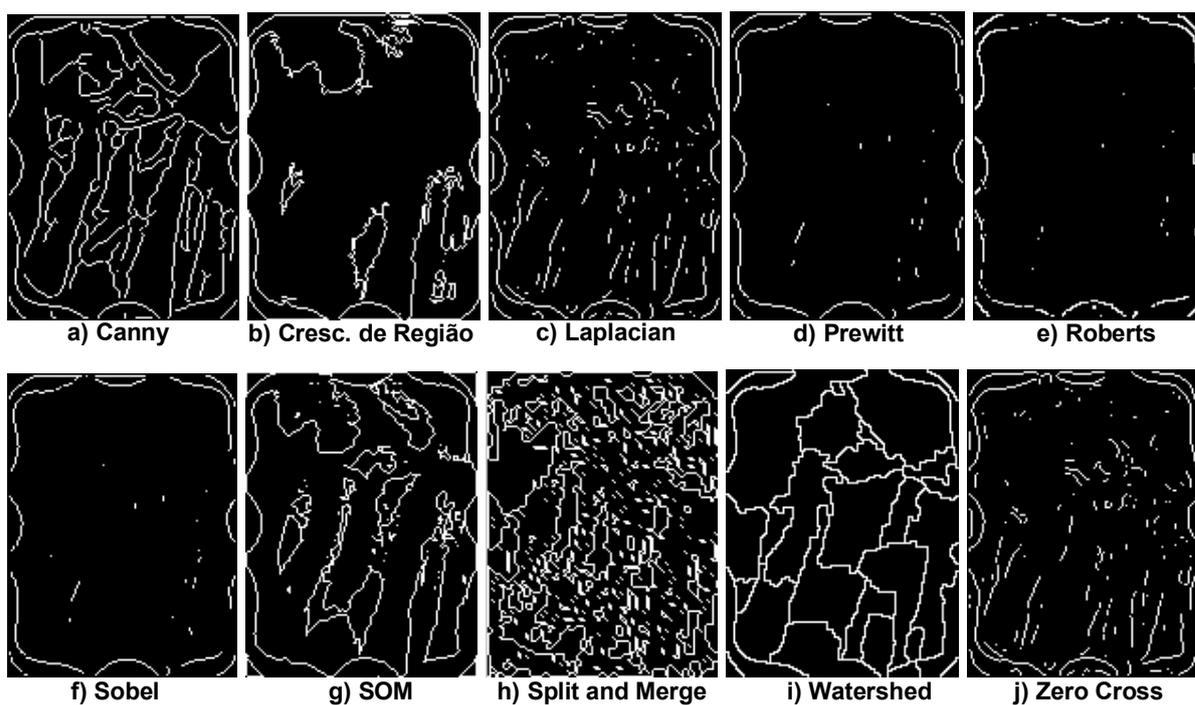
F.2 – IMAGENS ORIGINAIS APÓS A APLICAÇÃO DAS TÉCNICAS DE SEGMENTAÇÃO



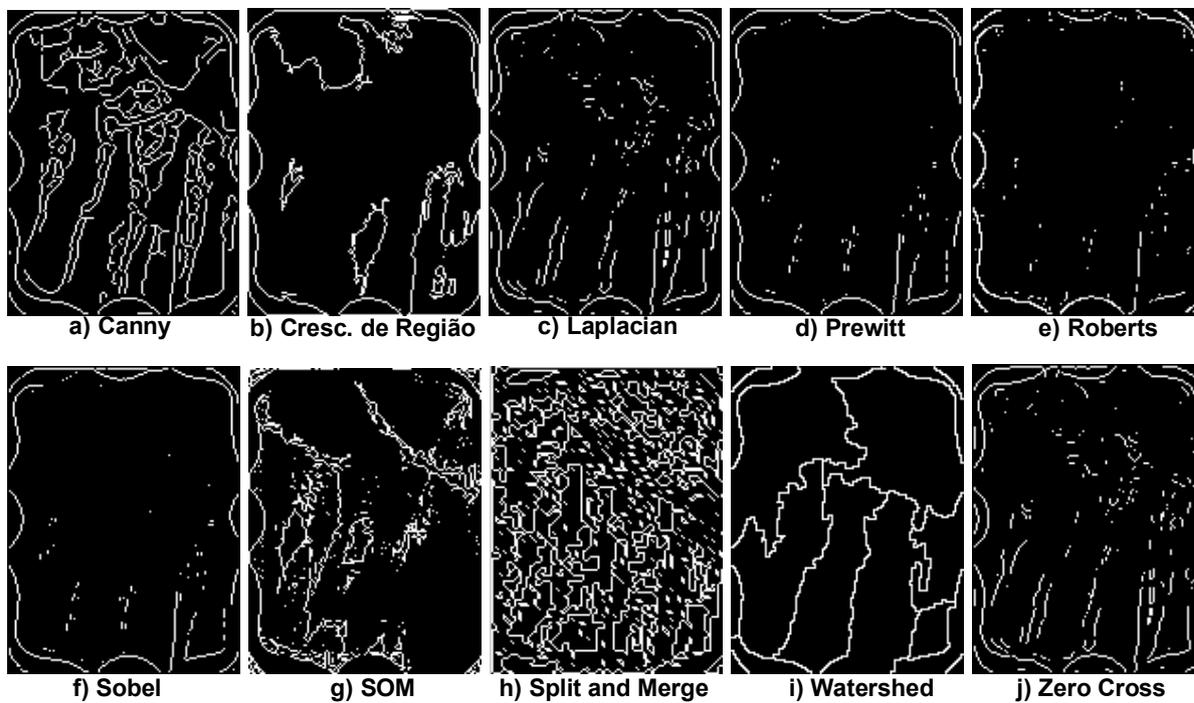
F.3 – IMAGENS COM O FILTRO DA MEDIANA SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO



F.4 – IMAGENS EQUALIZADAS SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO

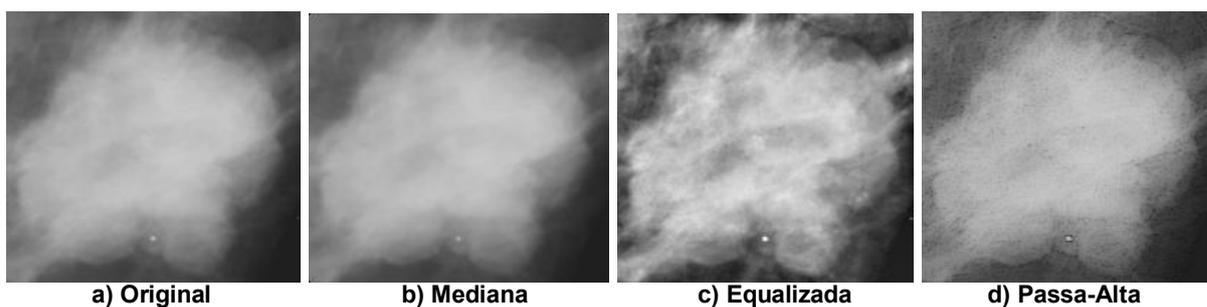


F.5 – IMAGENS COM O FILTRO PASSA-ALTA SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO

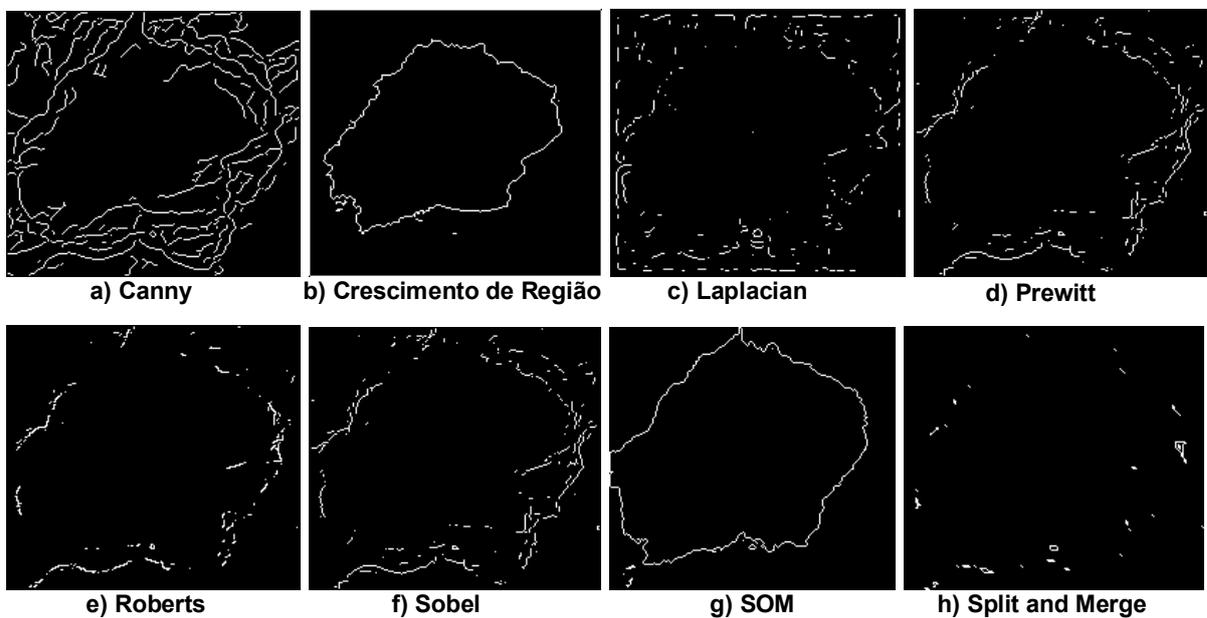


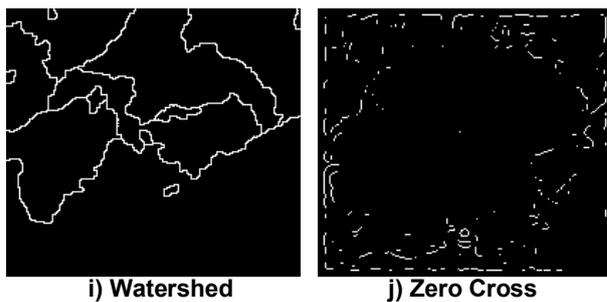
APÊNDICE G – IMAGENS DE NÓDULOS MAMOGRÁFICOS DA CLASSE MICROLOBULADA

G.1– IMAGENS ORIGINAIS SEGUIDAS DE FILTROS DE MELHORIA



G.2– IMAGENS ORIGINAIS APÓS A APLICAÇÃO DAS TÉCNICAS DE SEGMENTAÇÃO

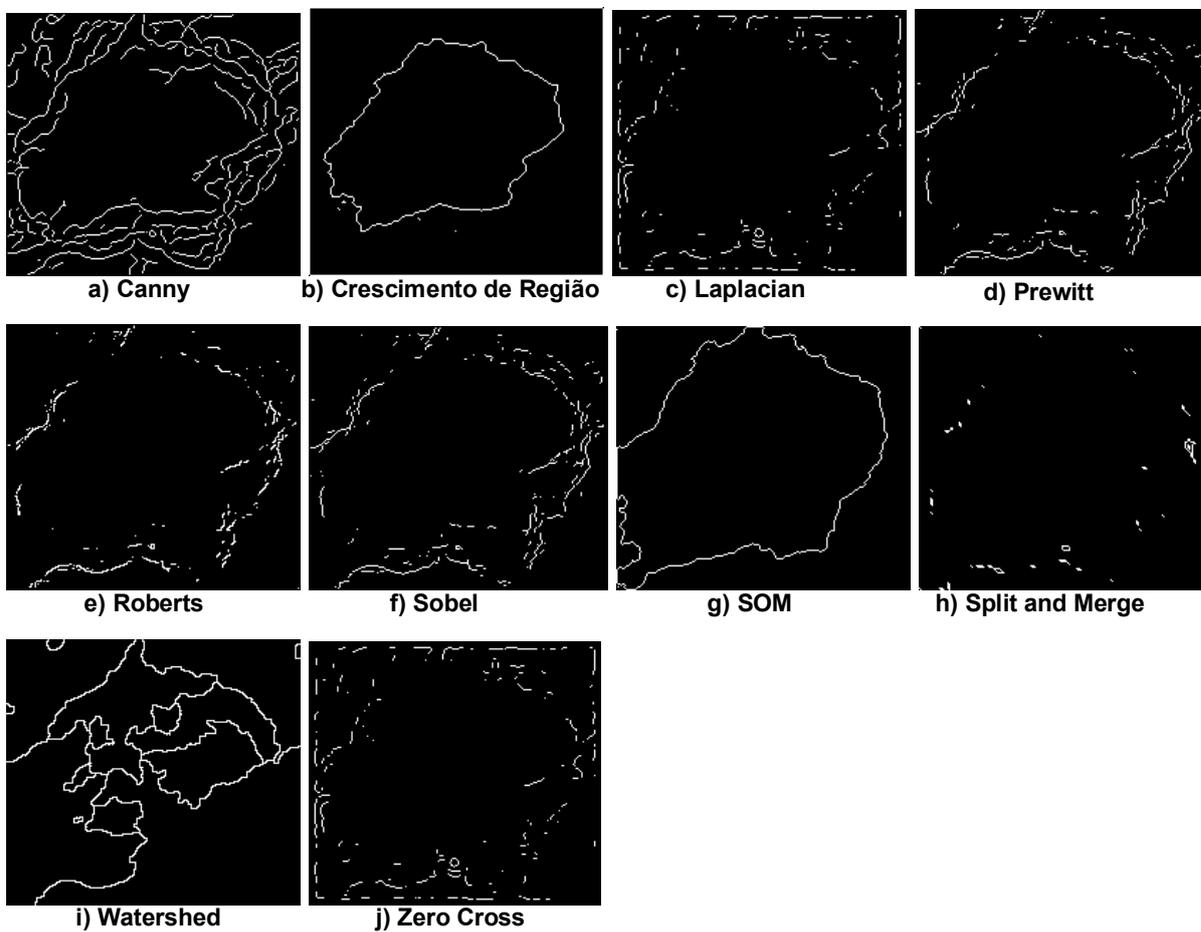




i) Watershed

j) Zero Cross

G.3- IMAGENS COM O FILTRO DA MEDIANA SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO



a) Canny

b) Crescimento de Região

c) Laplacian

d) Prewitt

e) Roberts

f) Sobel

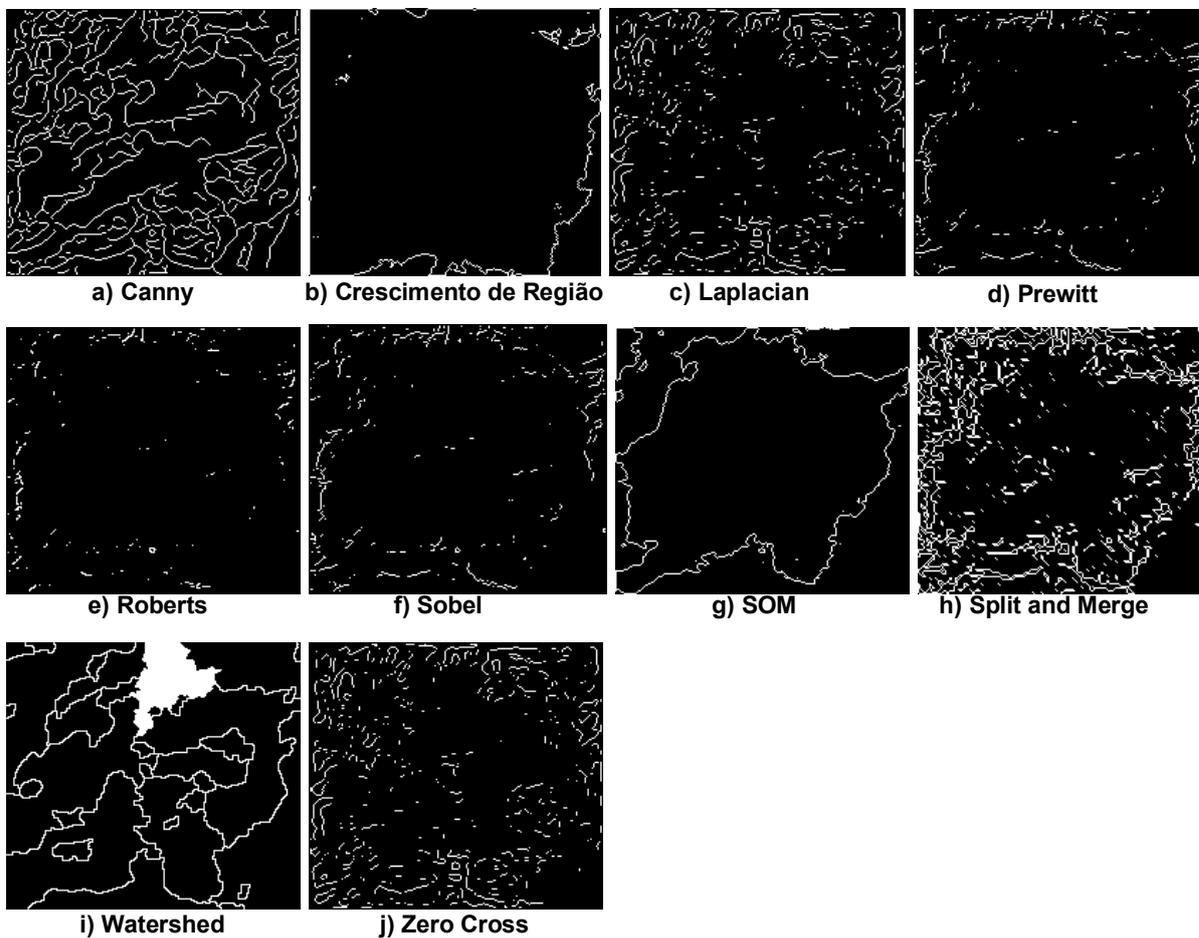
g) SOM

h) Split and Merge

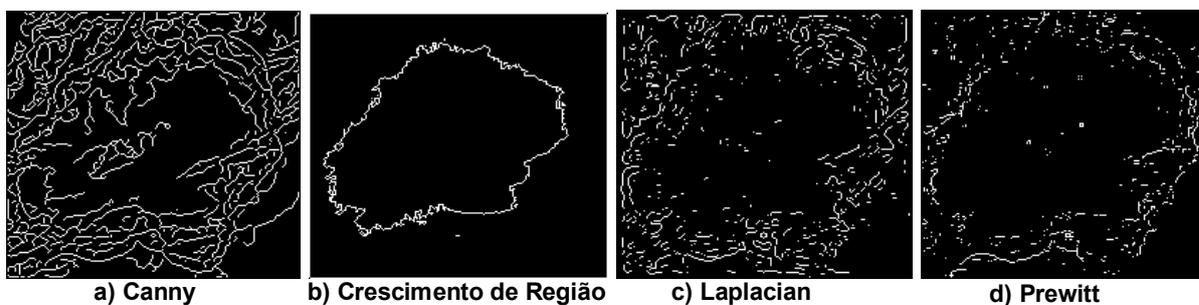
i) Watershed

j) Zero Cross

G.4– IMAGENS EQUALIZADAS SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO



G.5– IMAGENS COM O FILTRO PASSA-ALTA SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO

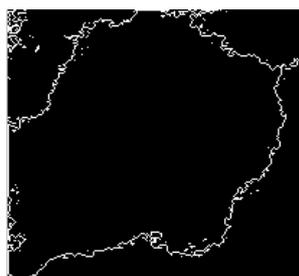




e) Roberts



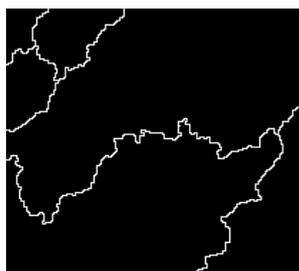
f) Sobel



g) SOM



h) Split and Merge



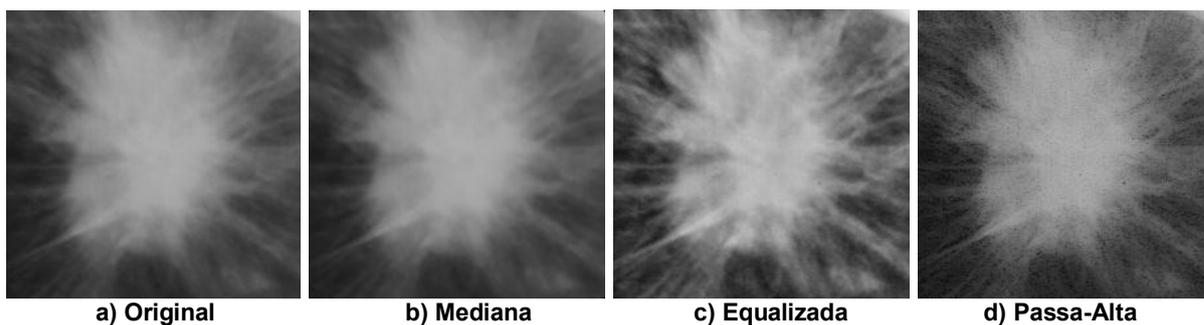
i) Watershed



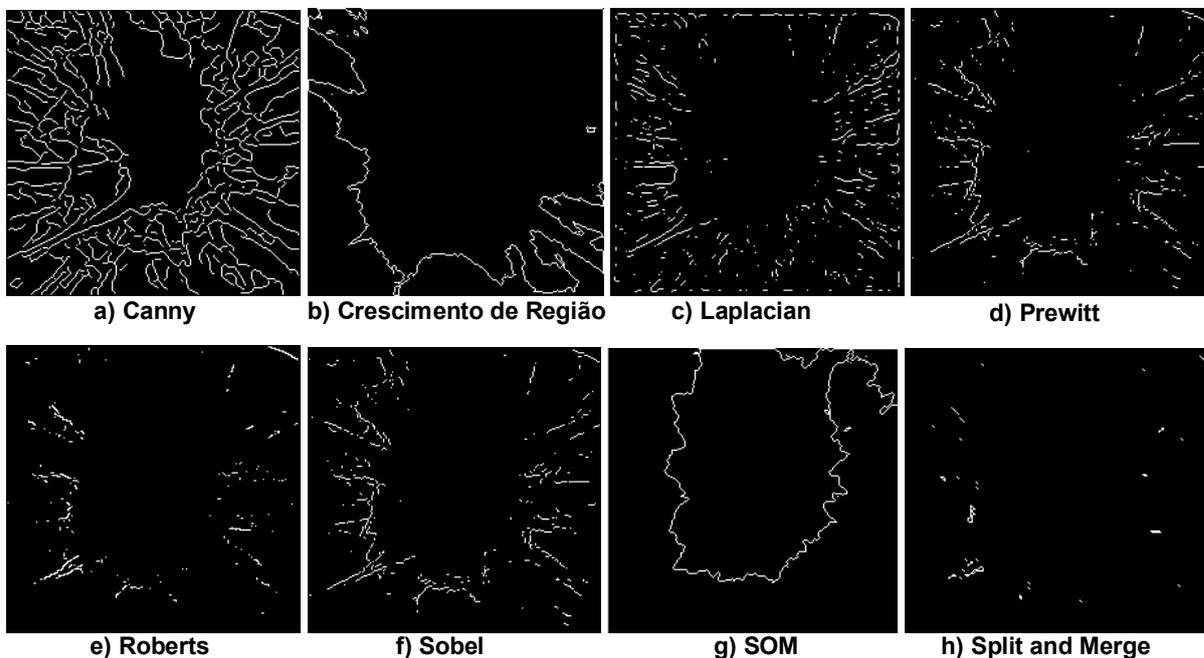
j) Zero Cross

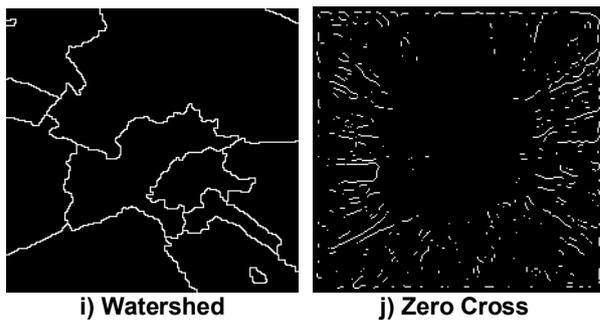
APÊNDICE H – IMAGENS DE NÓDULOS MAMOGRÁFICOS DA CLASSE ESPICULADA

H.1– IMAGENS ORIGINAIS SEGUIDAS DE FILTROS DE MELHORIA



H.2– IMAGENS ORIGINAIS APÓS A APLICAÇÃO DAS TÉCNICAS DE SEGMENTAÇÃO

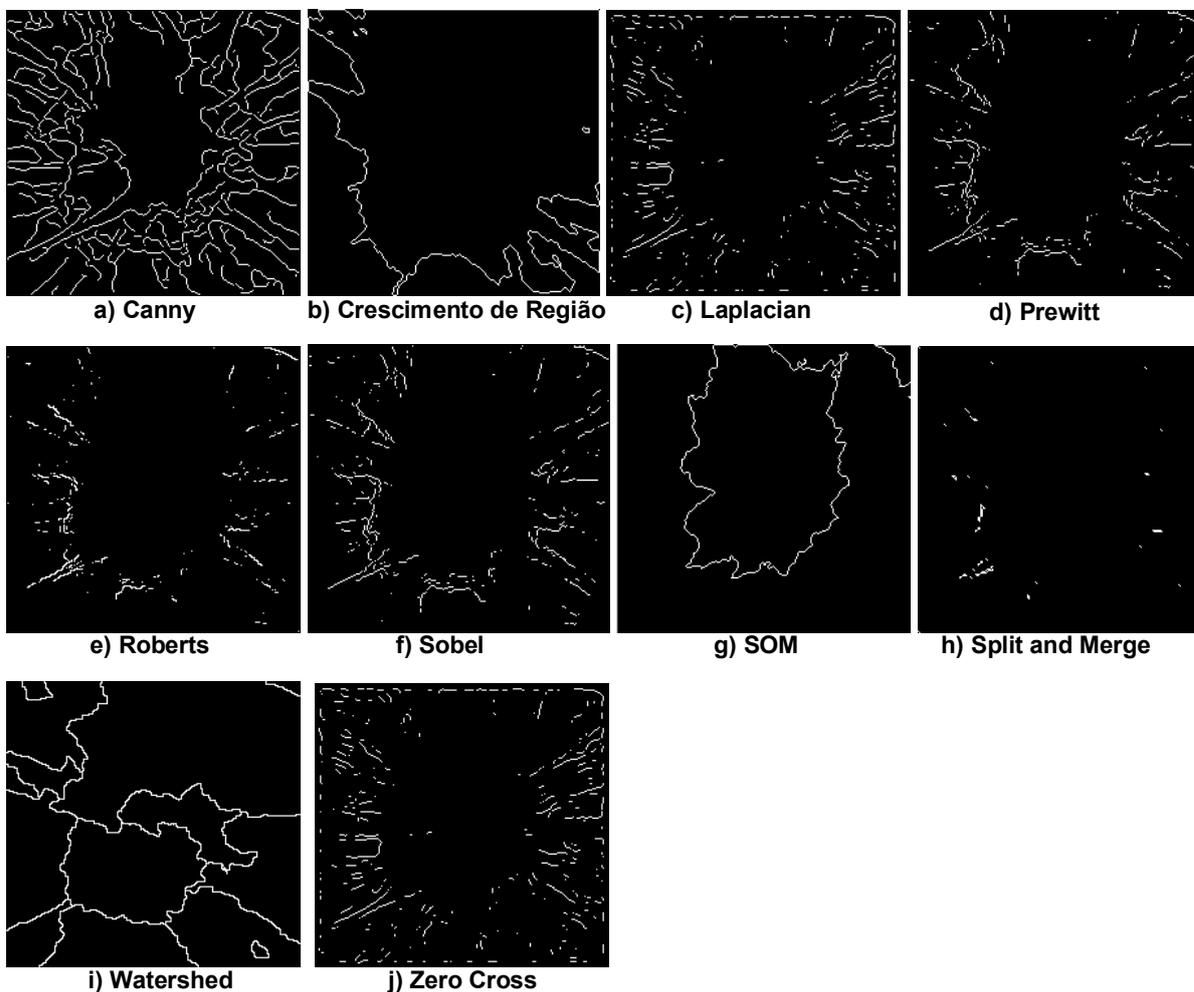




i) Watershed

j) Zero Cross

H.3– IMAGENS COM O FILTRO DA MEDIANA SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO



a) Canny

b) Crescimento de Região

c) Laplacian

d) Prewitt

e) Roberts

f) Sobel

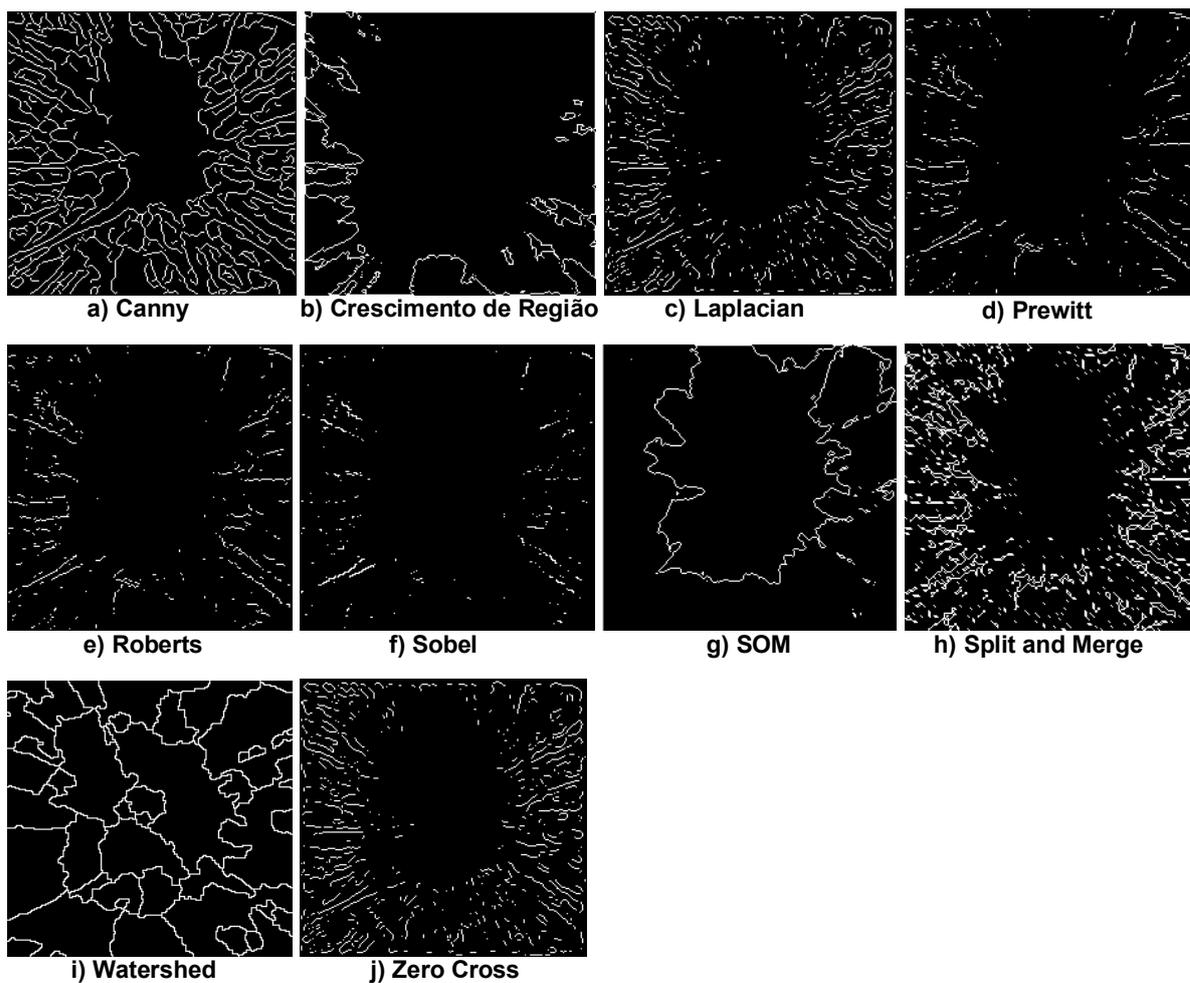
g) SOM

h) Split and Merge

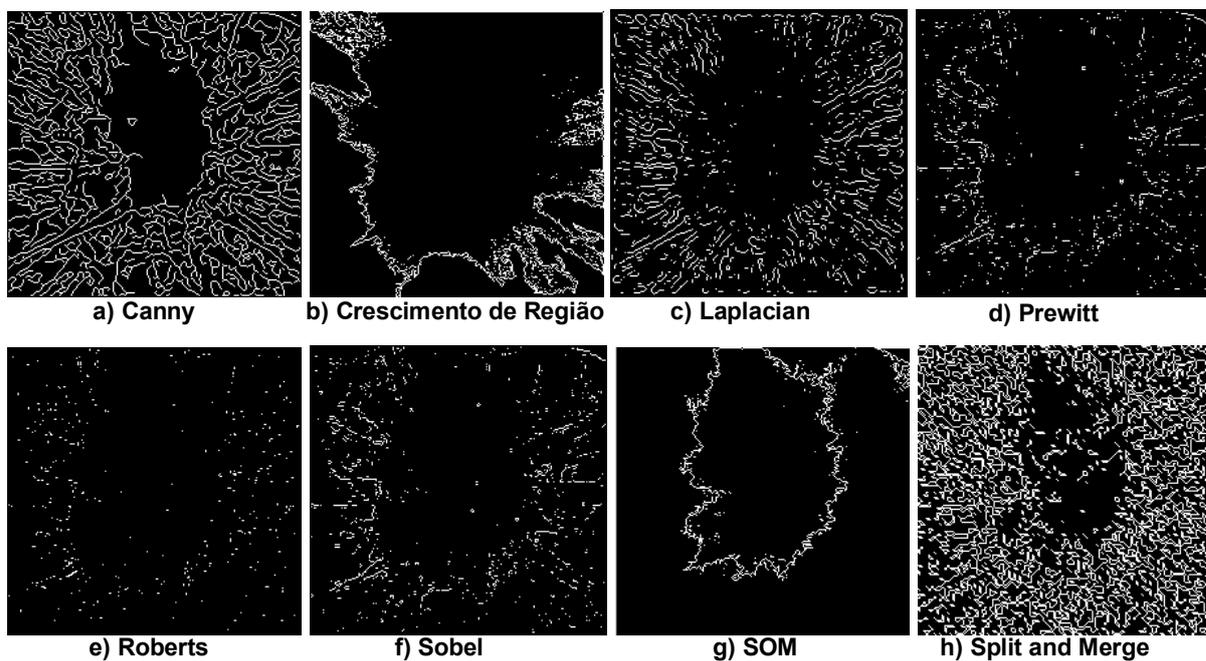
i) Watershed

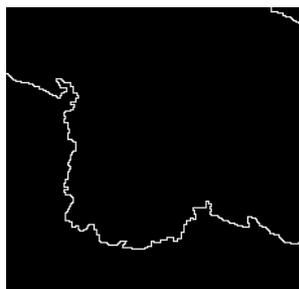
j) Zero Cross

H.4– IMAGENS EQUALIZADAS SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO

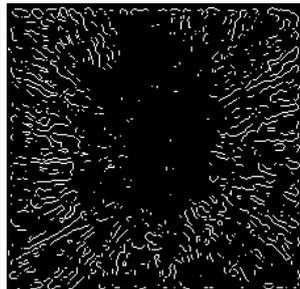


H.5– IMAGENS COM O FILTRO PASSA-ALTA SEGUIDAS DAS TÉCNICAS DE SEGMENTAÇÃO





i) Watershed



j) Zero Cross