

UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE ELETRICIDADE

JOBERTH DE NAZARÉ SILVA

**DETECÇÃO AUTOMÁTICA DE MASSAS EM MAMOGRAFIAS DIGITAIS
USANDO QUALITY THRESHOLD CLUSTERING E MVS**

São Luís

2013

JOBERTH DE NAZARÉ SILVA

**DETECÇÃO AUTOMÁTICA DE MASSAS EM MAMOGRAFIAS DIGITAIS
USANDO QUALITY THRESHOLD CLUSTERING E MVS**

Dissertação de Mestrado apresentado ao Programa de Pós-Graduação em Engenharia de Eletricidade da Universidade Federal do Maranhão, como parte dos requisitos para obtenção do título de Mestre em Engenharia de Eletricidade na área de concentração Ciência da Computação.

Orientador: Prof. Dr. Aristófanés Corrêa Silva

Co-orientador: Prof. Dr. Anselmo Cardoso Paiva

São Luís

2013

Silva, Joberth de Nazaré.

Detecção automática de massas em mamografias digitais usando quality threshold clustering e mvs / Joberth de Nazaré Silva – São Luís, 2013.

106 f.

Impresso por computador (fotocópia).

Orientador: Aristófanês Corrêa Silva.

Co-orientador: Anselmo Cardoso de Paiva.

Dissertação (Mestrado) – Universidade Federal do Maranhão, Programa de Pós-Graduação em Engenharia de Eletricidade, 2013.

1. Detecção automática de massas – Mamografia – máquinas de vetores de suporte. 2. Função correlograma. I. Título.

CDU 621.386.84:618.19

DETECÇÃO AUTOMÁTICA DE MASSAS EM MAMOGRAFIAS
DIGITAIS USANDO QUALITY THRESHOLD CLUSTERING E MVS

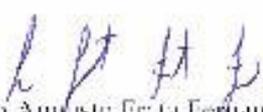
Joberth de Nazaré Silva

Dissertação aprovada em 26 de fevereiro de 2013.


Prof. Aristóteles Corrêa Silva, Dr.
(Orientador)


Prof. Anselmo Carlos de Paiva, Dr.
(Co-Orientador)


Prof. Alzaine Miranda dos Santos, Dra.
(Membro da Banca Examinadora)


Prof. Leandro Augusto Prieta Fernandes, Ph.D.
(Membro da Banca Examinadora)

À minha família e amigos

AGRADECIMENTO

A Jesus Cristo, pela força, perseverança e iluminação e a Nossa Senhora de Fátima, pela constante intercessão junto a Deus por mim.

A meus pais, José Ribamar Silva e Maria José de Nazaré por todo o apoio e auxílio durante essa jornada.

Ao meu orientador Prof. Aristófanés Silva, por ter acreditado em minha capacidade desde o começo do curso. Agradeço a ele pela sua compreensão e paciência nos momentos de dificuldade e principalmente pela sua disponibilidade em ajudar. Muito obrigado e que Deus lhe pague.

Ao meu co-orientador Prof. Anselmo Paiva, por seus ensinamentos, palavras de incentivo e compartilhamento de experiências.

A minha noiva Lívia Bianca da Silva Ferreira, pela compreensão, carinho, dedicação e paciência a mim dedicados.

A todos os colegas do LABPAI, por seus auxílios e companheirismo nas horas difíceis e em especial a Peterson pelas dúvidas tiradas.

Ao Programa de Pós-graduação em Engenharia de Eletricidade da Universidade Federal do Maranhão, a todos os professores, alunos e funcionários responsáveis pelo zelo dessa instituição.

À CAPES pelo financiamento do meu estudo durante esses dois anos.

A todos do meu grupo de oração Virgem Imaculada por suas orações.

“Até os adolescentes podem esgotar-se, e jovens robustos podem cambalear, mas aqueles que contam com o Senhor renovam suas forças; ele dá-lhes asas de águia. Correm sem se cansar, vão para a frente sem se fatigar”.

RESUMO

O câncer de mama é, mundialmente, a forma mais comum de câncer em mulheres afetando, em algum momento suas vidas, aproximadamente uma em cada nove a uma em cada treze mulheres que atingem os noventa anos no mundo ocidental (LAURANCE, 2006). O câncer de mama é ocasionado pela reprodução frequente de células de diversas partes do corpo humano. Em certos momentos e por motivos ainda desconhecidos algumas células começam a se reproduzir com uma velocidade maior, ocasionando o surgimento de massas celulares denominadas de neoplasias ou tumores que são tecidos de formação nova, mas de origem patológica. Neste trabalho foi proposto um método de detecção automática de massas em mamografias digitais usando o *Quality Threshold* (QT), e a Máquina de Vetores de Suporte (MVS). As etapas de processamento das imagens foram as seguintes: primeiramente veio a fase de pré-processamento que consiste em retirar o fundo da imagem, suavizá-la com um filtro passa-baixa, aumentar a escala de contraste, e na sequência realizar um realce com a Transformada de Wavelet (WT) através da alteração dos seus coeficientes com uma função linear. Após a fase de pré-processamento vem a segmentação utilizando o QT que segmenta a imagem em clusters com diâmetros pré-definidos. Em seguida, vem o pós-processamento com a seleção dos melhores candidatos à massa feita através da análise dos descritores de forma pela MVS. Para fase de extração de características de textura foram utiliza os descritores de Haralick e a função correlograma. Já na fase de classificação a MVS novamente foi utilizada para o treinamento, validação do modelo MVS e teste final. Os resultados alcançados foram: sensibilidade de 92,31%, especificidade de 82,2%, Acurácia de 83,53%, uma taxa de falsos positivos por imagem de 1,12 e uma área sob a curva FROC de 0,8033.

Palavras chave: Detecção Automática de Massas. *Quality Threshold* (QT). Função Correlograma. Máquina de Vetores de Suporte.

ABSTRACT

Breast cancer is worldwide the most common form of cancer affecting woman, sometimes in their lives, at the proportion of either one to nine or one to thirteen women who reach the age of ninety in the west world (LAURENCE, 2006). Breast cancer is caused by frequent reproduction of cells in various parts of the human body. At certain times, and for reasons yet unknown, some cells begin to reproduce at a higher speed, causing the onset of cellular masses called neoplasias, or tumors, which are new tissue formation, but from pathological origin. This work has proposed a method of automatic detection of masses in digital mammograms, using the Quality Threshold (QT), and the Supporting Vector Machine (MVS). The images processing steps were as follows: firstly, the pre-processing phase took place which consisted of removing the background image, smoothing it with a low pass filter, to increase the degree of contrast, and then, in sequence, accomplishing an enhancement of the Wavelet Transform (WT) by changing their coefficients with a linear function. After the pre-processing phase, came the segmentation with the use of the QT which divided the image in to clusters with pre-defined diameters. Then, the post-processing occurred with the selection of the best candidates to mass formed by the MVS analysis of the shape descriptors. For the extraction phase of texture features the Haralick descriptors and the function correlogram were used. As for the classification stage, the MVS was used again for training, validation of the MVS model and final test. The achieved results were: sensitivity of 92.31%, specificity of 82.2%, accuracy of 83,53%, a false positive rate per image of 1.12 and an area under a FROC curve of 0.8033.

Keywords: Automatic Detection of Masses. *Quality Threshold (QT)*. Correlogram Function, Máquina de Vetores de Suporte.

LISTA DE ABREVIATURA E SIGLAS

ASCFROC	Área Sob a Curva FROC
AUC	Área Sob A Curva ROC
CAD	<i>Computer Aided Detection</i>
CADx	<i>Computer Aided Diagnosis</i>
CC	Crânio-Caudal
CLBP	Padrão Binário Local Completo
DDSM	<i>Digital Database for Screening Mammography</i>
DWT	Transformada de <i>Wavelet</i> Discreta
ECM	Exame Clínico das Mamas
FN	Falso Negativo
FP	Falso Positivo
FPI	Falso Positivo por Imagem
FROC	<i>Free Response Operating Characteristic</i>
GLCM	<i>Co-occurrence Matrices of Gray Levels</i>
GNG	<i>Growing Neural Gas</i>
HH	Frequência Horizontal Alta e Frequência Vertical Alta
HL	Frequência Horizontal Alta e Frequência Vertical Baixa
INCA	Instituto Nacional de Câncer
LDA	<i>Linear Discriminant Analysis</i>
LH	Frequência Horizontal Baixa e Frequência Vertical Alta
LL	Frequência Horizontal Baixa e Frequência Vertical Baixa
MCL	Múltiplas Camadas Concêntricas
MIAS	<i>Mammography Image Analysis Society</i>
MLO	Médio-Lateral Oblíqua
MVS	Máquina de Vetores de Suporte
NBAC	<i>Narrow Band Based Active Contour</i>
OMS	Organização Mundial da Saúde
PDI	Processamento Digital de Imagens
PNN	Rede Neural Probabilística
QT	<i>Quality Threshold</i>
ROC	<i>Receiver Operating Characteristic</i>
ROI	<i>Region of Interest</i>

SRM	<i>Region Merging for Segmentation</i>
USF	Universidade de São Francisco
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo
WLD	<i>Descriptor Local Weber</i>
WT	Transformada de <i>Wavelet</i>
WTDB4	Transformada de <i>Wavelet Daubechies 4</i>

LISTA DE FIGURAS

Figura 1	Etapas do processo de metástase.....	25
Figura 2	Tecidos mamários e suas anormalidades. (a) massa espiculada; (b) micro - calcificações agrupadas e (c) distorção de arquitetura.....	26
Figura 3	Massas classificadas de acordo com suas bordas.....	26
Figura 4	Massas classificadas conforme os seus formatos.....	27
Figura 5	Exames mamográficos. (a) Imagem MLO; (b) Imagem CC.....	28
Figura 6	Etapas de um Sistema CAD.....	30
Figura 7	Grupo de coeficientes Wavelet.....	40
Figura 8	Realce com DWT: (a) imagem original, (b) imagem realçada com função linear.....	41
Figura 9	Ângulos para o cálculo na matriz de co-ocorrência.....	46
Figura 10	Correlograma: (a) amostras correlacionadas, (b) amostras não-correlacionadas.....	49
Figura 11	Ilustração dos pixels de origem (x_i), pixels de extremidade (y_i) e a distância h entre x_i e y_i	50
Figura 12	Hiperplano com vetores de suporte.....	52
Figura 13	Conjunto de dados (a) linearmente separáveis, (b) não-linearmente separáveis.....	53
Figura 14	Exemplo de curva FROC.....	55
Figura 15	Etapas da metodologia utilizada.....	57
Figura 16	Remoção das bordas laterais: (a) imagem com bordas laterais, (b) imagem com bordas laterais removidas.....	59
Figura 17	Imagem binarizada com nível de cinza 255 para o grupo que contém a mama e as marcações do especialista; e com nível de cinza 0 para o grupo que contém o fundo da mama.....	60
Figura 18	Mamografia evidenciando as regiões conexas com a cor verde após a aplicação do algoritmo de crescimento de região.....	60
Figura 19	Mamografia com o fundo, marcações dos especialistas e bordas laterais removidas.....	61
Figura 20	Fases da retirada do músculo peitoral: (a) Mamografia com o fundo, marcações dos especialistas e bordas laterais removidos, (b) imagem	

	dividida na metade da sua largura, (c) imagem que contém o lado com maior média dos níveis de cinza dos pixels que a compõem, (d) imagem com os pixels abaixo da metade da altura do lado que contém a maior média de nível de cinzas dos pixels removidos, (e) bordas detectas pelo filtro de Canny, (f) bordas com a mesma direção do músculo peitoral resultantes do operador morfológico de erosão, (g) reta resultante da transformada de Hough e (h) imagem sem o músculo peitoral.....	62
Figura 21	Elementos estruturantes: (a) para o músculo peitoral da esquerda, (b) para o músculo peitoral da direita.....	62
Figura 22	Máscara do filtro passa-baixa da média.....	63
Figura 23	Aplicação do filtro passa-baixa: (a) imagem sem o filtro passa-baixa e (b) imagem com o filtro passa-baixa.....	63
Figura 24	Aumento seletivo do contraste.....	64
Figura 25	Aplicação do aumento seletivo de contraste: (a) imagem com o filtro passa-baixa e (b) imagem com aumento seletivo de contraste.....	64
Figura 26	Imagem com quatro grupos de coeficientes.....	65
Figura 27	Aplicação do realce com a WT: (a) imagem com aumento seletivo de contraste e (b) imagem com realce WT.....	66
Figura 28	Mamografia segmentada com o QT.....	68
Figura 29	Clusters com formatos inadequados.....	68
Figura 30	Obtenção dos descritores de Haralick (a) cluster gerado pelo QT, (b) doze matrizes de co-ocorrência geradas do cluster, (c) seis descritores de Haralick extraído de cada matriz de co-ocorrência e (d) um total de 72 características geradas.....	70
Figura 31	Cluster quadrado com 85 pixels de lado e com o pixel de origem tendo pixels extremidades nas direções horizontal, vertical e diagonal e com o h variando de 1 a 85 nas três direções.....	71
Figura 32	Fluxo de análise dos resultados.....	73
Figura 33	Região segmentada dentro da marcação do especialista.....	80
Figura 34	Curva FROC.....	81
Figura 35	Primeiro estudo de caso: (a) Imagem com lesão demarcada pelo especialista, (b) imagem com fundo removido, (c) imagem realçada, (d) imagem segmentada pelo QT, (e) imagem com <i>clusters</i> removidos	

	pintados de branco e (f) imagem com massa detectada corretamente.....	84
Figura 36	Segundo estudo de caso: (a) Imagem com lesão demarcada pelo especialista, (b) imagem com fundo removido, (c) imagem realçada, (d) imagem segmentada pelo QT, (e) imagem com clusters removidos pintados de branco e, (f) imagem com massa detectada corretamente e outra detectada erroneamente.....	86
Figura 37	Terceiro estudo de caso: (a) Imagem com lesão demarcada pelo especialista, (b) imagem com fundo removido, (c) imagem realçada, (d) imagem segmentada pelo QT com um destaque para massa segmentada, (e) imagem com <i>clusters</i> removidos pintados de branco e, (f) imagem com falha total na detecção da massa.....	88
Figura 38	Quarto estudo de caso: (a) Imagem <i>normal</i> , (b) imagem com fundo removido, (c) imagem realçada, (d) imagem segmentada pelo QT, (e) imagem com <i>clusters</i> removidos pintados de branco e, (f) imagem <i>normal</i> sem massa detectada.....	90
Figura 39	Quinto estudo de caso: (a) Imagem <i>normal</i> , (b) imagem com fundo removido, (c) imagem realçada, (d) imagem segmentada pelo QT, (e) imagem com <i>clusters</i> removidos pintados de branco e, (f) imagem <i>normal</i> com massa inexistente detectada.....	91

LISTA DE TABELA

Tabela 1	Resumo das metodologias citadas acima.....	23
Tabela 2	Conjunto dos pixels A, B, C, D e F distribuidos de modo a possibilitar a relação de todos entre si.....	67
Tabela 3	Parametro C resultante da relação de todos os pixels entre si.....	67
Tabela 4	Elipses marcando os valores de C menores ou iguais a 100 e maiores ou iguais a 15 e com a última coluna indicando os pixels de todos os candidatos a <i>cluster</i> e destacando com um retângulo amarelo o <i>cluster</i> escolhido, ou seja, o que possui mais pixels.....	67
Tabela 5	Configuração dos clusters para treinamento e validação do modelo MVS....	71
Tabela 6	Configuração dos <i>clusters</i> de <i>massas</i> e <i>não-massas</i> de acordo com as medidas geométricas para treinamento e validação do modelo MVS.....	75
Tabela 7	Resultados alcançados para a validação do modelo MVS gerado de acordo com os descritores de forma.....	76
Tabela 8	Resultados alcançados com as configurações para o treinamento e validação do modelo MVS com as medidas de textura.....	77
Tabela 9	Distribuição dos clusters com 50% para o treinamento do classificador e 50% para validação do modelo MVS.....	77
Tabela 10	Distribuição dos clusters com 70% para o treinamento do classificador e 30% para validação do modelo MVS.....	78
Tabela 11	Resultados alcançados com as configurações para o treinamento e validação do modelo MVS com as medidas de textura.....	78
Tabela 12	Resultados alcançados com o teste.....	81
Tabela 13	Comparação entre os resultados da metodologia proposta e os das metodologias citadas no Capítulo 2.....	92

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Organização do trabalho	19
2	TRABALHOS RELACIONADOS	20
3	FUNDAMENTAÇÃO TEÓRICA	25
3.1	O câncer de mama	25
3.2	Mamografia	28
3.3	Sistemas CAD/CADx	29
3.4	Processamento de imagens digitais	31
3.4.1	K-means.....	33
3.4.2	Crescimento de região.....	33
3.4.3	Filtro de Canny.....	34
3.4.4	Morfologia matemática.....	35
3.4.4.1	<i>Elemento estruturante</i>	36
3.4.4.2	<i>Processo de erosão de imagens</i>	36
3.4.5	Transformada de Hough.....	37
3.4.5.1	<i>Identificação das retas</i>	37
3.4.6	Filtro passa-baixa.....	38
3.4.7	Aumento seletivo de contraste.....	39
3.4.8	Realce com a transformada de wavelet.....	40
3.4.9	Clusterização com quality threshold (QT).....	41
3.4.10	Medidas geométricas.....	42
3.4.10.1	<i>Excentricidade (E)</i>	43
3.4.10.2	<i>Circularidade (C)</i>	43
3.4.10.3	<i>Compacidade (C_o)</i>	44
3.4.10.4	<i>Densidade circular (D_c)</i>	44
3.4.11	Descritores de textura.....	44
3.4.11.1	<i>Matriz de co-ocorrência</i>	45
3.4.11.2	<i>Descritores de Haralick</i>	46
3.4.11.2.1	<u>Segundo momento angular</u>	46
3.4.11.2.2	<u>Contraste</u>	47

3.4.11.2.3	<u>Correlação</u>	47
3.4.11.2.4	<u>Entropia</u>	47
3.4.11.2.5	<u>Variância</u>	48
3.4.11.2.6	<u>Homogeneidade</u>	48
3.4.12	Função geoestatística.....	48
3.4.12.1	<i>Correlograma</i>	49
3.4.13	Máquina de vetores de suporte.....	51
3.4.13.1	<i>Hiperplano ótimo</i>	51
3.4.13.2	<i>MVS para padrões não-linearmente separáveis</i>	53
3.4.14	Validação de resultados.....	54
4	METODOLOGIA	57
4.1	Aquisição das imagens	58
4.2	Pré-processamento	58
4.2.1	Retirada do fundo da mamografia crânio caudal (CC).....	59
4.2.2	Retirada de Músculo Peitoral da Mamografia Médio Lateral Oblíquo (MLO).....	61
4.2.3	Filtragem com o filtro passa-baixa.....	63
4.2.4	Aumento seletivo de contraste.....	63
4.2.5	Realce com a transformada de wavelet.....	64
4.3	Segmentação	66
4.4	Pós-processamento	68
4.5	Extração de características de texturas	69
4.5.1	Descritores de Haralick.....	69
4.5.2	Função correlograma.....	70
4.6	Classificação	71
5	RESULTADOS E DISCURSÃO	73
5.1	Treinamento e validação do modelo MVS	74
5.1.1	Seleção dos melhores candidatos à massa.....	74
5.1.2	Treinamento e validação do modelo MVS com medidas de textura.....	76
5.2	Teste	79
5.2.1	Segmentação com o QT dos exames.....	80

5.2.2	Análise da curva FROC dos resultados do teste.....	81
5.3	Estudos de casos.....	82
5.3.1	Primeiro caso.....	82
5.3.2	Segundo caso.....	85
5.3.3	Terceiro caso.....	87
5.3.4	Quarto caso.....	89
5.3.5.	Quinto caso.....	90
5.4	Comparação com os resultados dos trabalhos relacionados.....	92
6	CONCLUSÃO.....	94
	REFERÊNCIAS.....	96

1 INTRODUÇÃO

Mesmo com todas as evoluções no tratamento do câncer, essa patologia ainda é uma das que mais assusta. As pessoas, quando pensam em câncer, já se remetem à mutilação, à perda do cabelo, à morte. A própria pronúncia da palavra é feita de forma pesada. O câncer é uma das doenças mais temidas e ainda causa espanto, piedade, repulsa, preconceito e discriminações. Conviver com essa doença e vencê-la requerem esforços e uma verdadeira e autêntica “aliança” entre o paciente, a rede de apoio familiar e social, a equipe médica e de saúde e a própria comunidade, que tem de estar disposta a acolher.

Nos últimos anos, o câncer ganhou uma grande dimensão, convertendo-se em um destacado problema de saúde pública mundial. A Organização Mundial da Saúde (OMS, 2012) estimou que, no ano 2030, poder-se-ão esperar 27 milhões de casos incidentes de câncer, 17 milhões de mortes por câncer e 75 milhões de pessoas vivas, anualmente, com câncer. O maior efeito desse aumento irá incidir em países de baixa e média rendas (INCA, 2012).

Nos países pobres e emergentes, os cânceres predominantes são os de estômago, fígado, cavidade oral e colo do útero. Embora tentando-se criar padrões mais característicos de países ricos em relação aos pobres e emergentes, o padrão está mudando rapidamente, e vem-se observando aumento progressivo nos cânceres de pulmão, mama e cólon e reto, os quais, historicamente, não apresentavam essa importância e magnitude (INCA, 2012).

No Brasil, as estimativas para o ano de 2012 serão válidas também para o ano de 2013, apontando-se a ocorrência de aproximadamente 518.510 casos novos de câncer, com inclusão dos casos de pele não melanoma, reforçando-se a magnitude do problema do câncer no país. Sem os casos de câncer da pele não melanoma, estima-se um total de 385 mil casos novos. Os tipos mais incidentes serão os cânceres de pele não melanoma, próstata, pulmão, cólon e reto e estômago para o sexo masculino; e os cânceres de pele não melanoma, mama, colo do útero, cólon e reto e glândula tireoide para o sexo feminino (INCA, 2012).

Segundo tipo mais frequente no mundo, o câncer de mama é o mais comum entre as mulheres, respondendo por 22% dos casos novos a cada ano. No Brasil, as taxas de mortalidade por câncer de mama continuam elevadas, muito provavelmente porque a doença ainda é diagnosticada em estágios avançados. Na população mundial, a sobrevida média após cinco anos é de 61%. Relativamente raro antes dos 35 anos. Acima desta faixa etária sua incidência crescerá rápida e progressivamente. Estatísticas indicam aumento de sua incidência tanto nos países desenvolvidos quanto nos em desenvolvimento. Segundo a Organização

Mundial da Saúde (OMS, 2012), nas décadas de 60 e 70 registrou-se um aumento de 10 vezes nas taxas de incidência ajustadas por idade nos Registros de Câncer de Base Populacional de diversos continentes (INCA, 2012).

As maneiras mais eficazes para detectar-se precocemente o câncer de mama são o exame clínico da mama e a mamografia. O Exame Clínico das Mamas (ECM) pode detectar um tumor de até um centímetro quando este está em uma localização superficial. Segundo INCA (2012) o ECM deve contar com as seguintes etapas: inspeção estática e dinâmica, palpação das axilas e palpação das mama com a paciente em decúbito dorsal.

A mamografia é o exame mais indicado para detecção precoce do câncer de mama, uma vez que possibilita a detecção visual de possíveis estruturas que possam evidenciar a presença ou ausência deste tipo de câncer (GIGER; MACMAHON, 2000).

Contudo, a avaliação do exame mamográfico é subjetiva, requerendo grande habilidade do radiologista. Nas últimas décadas, técnicas computacionais vêm sendo desenvolvidas com o propósito de detectar automaticamente estruturas que possam estar associadas a tumores nos exames de mamografia, visando melhorar a taxa de detecção precoce de estruturas de interesse ligadas ao câncer de mama (GIGER; MACMAHON, 2000) (DENGLER *et al.*, 1993). Esses esquemas de processamento são conhecidos como sistemas CAD (“*Computer Aided Detection*”) e CADx (“*Computer Aided Diagnosis*”), e já estão presentes em diversos centros de diagnóstico por imagem, principalmente em países do primeiro mundo, como EUA e alguns países da Europa (TAYLOR *et al.*, 2004) (MORERA *et al.*, 2007). Os sistemas CAD e CADx fornecem uma segunda opinião, auxiliando o radiologista na interpretação de resultados que, em muitos casos, torna-se difícil devido às distorções que esse tipo de imagem sofre no seu processo de aquisição.

Neste trabalho é proposta uma metodologia para detecção automática de massas em mamografias digitais. O procedimento consta de um pré-processamento para realce das imagens com filtro passa-baixa, um aumento da escala de contraste e Transformada de *Wavelet* (WT).

Depois é realizada uma clusterização com *Quality Threshold* (QT) e em seguida um pós-processamento para redução dos candidatos a massa através das medidas geométricas e; em seguida, a extração das características será feita com os Descritores de Haralick e a Função Correlograma; e, por fim, a classificação será realizada com a Máquina de Vetores de Suporte (MVS).

A contribuição desta pesquisa acadêmica pontua-se na detecção de regiões suspeitas de câncer de mama a partir de mamografias digitais utilizando o QT para

segmentação das regiões de interesse e medidas geoestatísticas para extração de textura dos mamogramas. A utilização de ambas as técnicas constitui uma importante colaboração para as metodologias CADx e para as literaturas relacionadas a esta área. Além disso, com os resultados relevantes obtidos neste trabalho o mesmo poderá ser utilizado como uma metodologia que servirá para auxiliar os especialistas nas análises das mamografias sendo a mesma imune à variabilidade humana resultante da percepção e da tomada de decisões.

1.1 Organização do trabalho

Este trabalho está organizado em mais quatro capítulos, descritos a seguir.

É apresentado, no Capítulo 2, um resumo de alguns trabalhos relacionados, a indicação de algumas deficiências dos mesmos e a solução proposta nesta metodologia.

No Capítulo 3, é abordada a fundamentação teórica para o desenvolvimento da metodologia proposta. Nele foi trabalhado o filtro passa-baixa, o aumento seletivo da escala de contraste e o realce com a WT (Transformada de *Wavelet*) que são etapas do pré-processamento. O Agrupamento com Limiar de Qualidade (do inglês, *Quality Threshold Clustering*) utilizada na segmentação das mamas. As medidas geométricas usadas em um pós-processamento para seleção dos melhores candidatos a massa. Os Descritores de Haralick e a Função Correlograma foram utilizados para extração das características de texturas. A MVS foi utilizada para classificação.

É feita, no Capítulo 4, uma descrição da metodologia proposta dividida em quatro etapas: o pré-processamento das imagens, a segmentação da mama, a extração de características e a classificação das regiões de interesse em *massa* ou *não-massa*.

São apresentados e discutidos os resultados no Capítulo 5.

No Capítulo 6, faz-se uma conclusão do trabalho, abordando-se a eficácia da metodologia utilizada e propostas para trabalhos futuros.

2 TRABALHOS RELACIONADOS

Na literatura, têm-se trabalhos reconhecidos que tratam do mesmo problema abordado pelo método proposto, ou seja: uma metodologia que auxilie os especialistas na detecção de massas em mamografias digitais.

Martins *et al.* (2007) apresentam uma metodologia que utiliza o índice de Moran e os coeficientes de Gearys como medidas a serem extraídas das regiões suspeitas das mamografias com a finalidade de distingui-las entre *normais* e *anormais* bem como classificá-las em *benignas* e *malignas*. Ambas as técnicas propostas mostraram-se muito promissoras, uma vez que foi obtida uma acurácia de 96,04% e uma área sob a curva ROC de 0,946 com coeficiente de Geary e uma acurácia de 99,39% e uma área sob a curva ROC (AUC) de 1 com índice de Moran para discriminar os tecidos das mamografias como *normais* ou *anormais*. A metodologia também alcançou uma acurácia de 88,31% e uma área sob a curva ROC (*Receiver Operating Characteristic*) de 0,804 com coeficiente de Geary e uma acurácia de 87,80% com uma área sob a curva ROC de 0,89 com índice de Moran para discriminar os tecidos das mamografias em *benignos* ou *malignos*.

Martins *et al.* (2009a) sugerem uma técnica que usou *Growing Neural Gas* (GNG) para segmentar os candidatos a lesão e a MVS junto com a função K de Ripley para detecção das massas. Nessa metodologia foram utilizadas 997 imagens do banco DDSM (*Digital Database for Screening Mammography*), sendo que 436 foram utilizadas para treino e teste e 561 foram utilizadas para avaliação do processo de detecção de massas. Os resultados obtidos foram 89,30% de sensibilidade, 0,93 falsos positivos por imagem e 0,02 falsos negativos por imagem.

Martins *et al.* (2009b) apresentam uma metodologia para a detecção de massas em mamografias digitais usando o algoritmo K-means para a segmentação da imagem e a matriz de co-ocorrência para descrever a textura das estruturas segmentadas. A classificação destas estruturas é realizada através da MVS, que os separam em dois grupos: *massas* e *não-massas*. A metodologia obteve 85% de acurácia.

Nunes (2009) propõe um trabalho para detectar massas que utiliza o algoritmo K-means e a técnica de Template Matching para segmentação das regiões suspeitas. A pesquisa foi testada com 650 imagens obtidas da base DDSM. A segmentação das regiões de interesse conseguiu segmentar 603 massas da amostra, o que foi equivalente a 92,77% dos casos, e também selecionou 2076 não-massas. Logo após, as medidas de geometria e textura foram extraídas de cada uma dessas regiões, sendo a textura descrita através do Índice Diversidade de Simpson. Por fim, essas informações foram submetidas a uma MVS para que as regiões suspeitas fossem classificadas em *massas* ou *não-massas*. A acurácia média foi de 83,94%, a

sensibilidade de 83,24%, a especificidade de 84,14% e 0,55 falsos positivos por imagem e 0,17 falsos negativos por imagem.

Foi apresentado por Bajger *et al.* (2010) um método automático para detecção de massas em mamografias que utiliza a segmentação da região de interesse por fusão estatística (SRM) e análise discriminante linear (LDA). O desempenho da metodologia foi avaliada em 36 imagens selecionadas a partir de um banco de dados proprietário de mamografias e em 48 imagens retiradas do DDSM. O valor da AUC para a classificação de cada região foi 0,90 para as imagens proprietárias e 0,96 para as imagens DDSM.

Xiaoming *et al.* (2011) apresentaram um sistema de detecção automática de massas em imagens mamográficas. Esse sistema combina a técnica de Múltiplas Camadas Concêntricas (MCL) que é um método que realiza a primeira segmentação utilizando o crescimento de região através do conhecimento prévio das características das massas. Logo após, através da técnica de Região com Faixa Estreita baseada no Contorno Ativo (NBAC), é feito um refinamento no contorno das regiões de interesse (ROIs) encontradas na etapa anterior. Em seguida, através do Padrão Binário Local Completo (CLBP), foram extraídas as características de textura das ROIs para serem classificadas por meio da MVS. O método foi avaliado com um conjunto de 231 imagens, contendo 245 massas. Dessas imagens, 125 contendo 133 massas foram utilizadas para treinar o MVS. O restante foram utilizadas para testar o desempenho. Foi obtida uma taxa de 1,36 falsos positivos por imagem e uma sensibilidade de 76,8%.

Mutaz *et al.*(2011) detectou massas em mamografias digitais através de estatísticas de segunda ordem. A extração das características das texturas da região segmentada de interesse (ROI, do inglês region of interest) foi feita por meio de Matrizes de Co-ocorrência dos Níveis de Cinza (GLCM), que são extraídas das quatro orientações espaciais: horizontal, diagonal para direita, diagonal para esquerda e vertical, correspondendo a uma inclinação em relação ao eixo horizontal, respectivamente, de 0°, 45°, 90° e 135°, com a distância de dois pixels para três diferentes tamanhos de janelas (8x8, 16x16 e 32x32). Os resultados mostraram que a GLCM em 0°, 45°, 90° e 135° com uma janela de tamanho 8x8 produziram os melhores resultados alcançando uma sensibilidade e especificidade de 91,67% e 84,17% respectivamente.

Abdalla e Mutaz *et al.*(2011) propõem uma metodologia para classificação automática de massas em mamografias digitais. Essa metodologia utilizou os descritores de Haralick derivado da matriz de co-ocorrência dos níveis de cinza para extração das características de textura. Primeiramente foi diminuído os níveis de cinza das imagens de

256 níveis de cinza para 16 níveis visando a redução dos dados e conseqüentemente o tempo de processamento. Em seguida, para cada nível de cinza foi atribuído um número de código. Assim, a imagem original é transformada em uma imagem codificada e em seguida as características de textura Haralick da matriz de co-ocorrência foram extraídas. A metodologia alcançou uma acurácia de 95,85%.

Foi apresentada por Mini (2011) uma nova abordagem para a classificação de mamografias digitais em classes *normais* e *anormais* para detecção de câncer de mama. Em primeiro lugar, as estruturas das mamografias produzidas por tecido glandular normal de densidade variável são eliminadas usando uma WT baseada na subtração média. Em seguida, as marcas lineares formadas pelo tecido normal conjuntivo são identificadas e removidas. Qualquer anormalidade que possa existir na mamografia é, portanto, aumentada na imagem residual, o qual torna a decisão sobre a normalidade da mamografia muito mais fácil. Características derivadas a partir das imagens residuais são aplicadas a uma Rede Neural Probabilística (PNN) para classificação. Os resultados alcançados foram uma sensibilidade de 58% e uma acurácia de 60% para os casos *normais* e uma sensibilidade de 91% e uma acurácia de 94,2% para os casos *anormais*.

Abubaker (2012) propôs um método para detecção de massas através da decomposição da WT e da MVS. A metodologia consiste na extração de características das regiões de interesse com a WT e a classificação com a MVS. Na segmentação das massas da base de imagens MIAS (*Mammography Image Analysis Society*) e das imagens mamográficas da Universidade de São Francisco (USF), foram utilizadas duas máscaras concêntricas: a interior com $70\mu\text{m} \times 70\mu\text{m}$ e a exterior com $101\mu\text{m} \times 101\mu\text{m}$. Foi calculada a média dos pixels de ambas e aquela que estivesse demarcando a região com maior média de nível de cinza era preservada e a outra era desconsiderada. Em seguida, um limiar global foi definido em cima da intensidade média das regiões com maiores níveis de cinza. Então, realizou-se uma binarização da imagem atribuindo-se zero para as regiões que estivessem abaixo daquele limiar e duzentos de cinquenta e cinco para aquelas que estivessem acima. Em seguida, um processo de erosão morfológica foi aplicado para remover áreas muito pequenas e reduzir as outras com ramificações indesejadas. Logo após, foi rotulado cada objeto da mamografia e calculada a quantidade de pixels de cada um, sendo igualado a duzentos e cinquenta e cinco os valores que estivessem entre 200 e 18000 pixels e a zero os demais. Na extração de características realizou-se a WT Daubechies 4 a partir da qual foram extraídos os coeficientes da imagem de baixa frequência, o valor máximo e mínimo dos coeficientes, a sua média e o desvio padrão entre os coeficientes. Após a extração de características foi realizada a

classificação com o MVS obtendo como resultados uma taxa de 0,05 falsos positivos por imagem e uma acurácia de 94%.

Foi proposta em Hussain e Khan (2012) a representação das propriedades texturais das mamografias utilizando *Descriptor Local Weber* (WLD). O descritor WLD foi usado para representar as propriedades estatísticas das massas e reduzir a taxa de falsos positivos e negativos por imagem. O WLD constrói estatísticas sobre micropadrões salientes, juntamente com a orientação do gradiente do pixel atual. Ele é robusto contra alterações de ruído e iluminação. O descritor WLD básico integra o conteúdo de informação local em um histograma único. Com a sua estenção em um descritor WLD espacial, melhor são codificadas tanto a aparência da região local quanto a da estrutura espacial das massas. A MVS foi empregada para a classificação das regiões suspeitas em *massas* e *não-massas*. A acurácia do sistema proposto foi de 98,8% no banco de dados DDSM.

Os bancos de filtros de Gabor, que permitem a manipulação de diversos parâmetros como frequência, orientação, excentricidade e simetria, foram utilizados por Hussain e Khan (2012) para extrair a textura espacial local das propriedades das massas que estão presentes nas mamografias em diferentes escalas e orientações. No sistema, são avaliadas 512 ROIs estando divididas em 256 *massas* e 256 *não-massas* extraídas das mamografias da base de dados DDSM. Nos experimentos realizados com bancos filtro de Gabor se tem diferentes números de orientações e escalas para encontrar a melhor parametrização. Usando esse recurso de extração de características e a MVS com validação cruzada, foi obtida uma acurácia de 99,5 %.

Por meio da Tabela 1, podemos observar um esquema que traz algumas informações dos trabalhos acima citados como a base de mamografias utilizada, a sensibilidade, a especificidade e a área sob a curva ROC.

Tabela 1: Resumo das metodologias citadas neste capítulo

Metodologia	Base	Sensibilidade (%)	Especificidade (%)	Acurácia (%)	AUC
Martins <i>et al.</i> (2007)	DDSM	-	-	99,39	1
Martins <i>et al.</i> (2009a)	DDSM	89,30	-	-	-
Martins <i>et al.</i> (2009b)	DDSM	-	-	85	-
Nunes (2009)	DDSM	83,24	84,14	83,94	-
Mariusz <i>et al.</i> (2010)	Proprietária	-	-	-	0,9
Xiaoming <i>et al.</i> (2011)	DDSM	76,8	-	-	-
Mutaz (2001)	DDSM	91,67	84,17	-	-
Abdalla e Mutaz (2001)	DDSM	-	-	95,85	-
Mini (2011)	MIAS	58	-	60	-
Abubaker (2012)	MIAS	-	-	94	-
Hussain e Khan (2012)	DDSM	-	-	98,8	-
Hussain <i>et al.</i> (2012)	DDSM	-	-	99,5	-

Os trabalhos relacionados acima expressam que as novas metodologias para detecção de massas em mamografias são promitentes. Outro ponto importante é a utilização do banco de imagens públicas DDSM que ganha destaque pela quantidade de trabalhos que o utilizou. Ele possui uma grande quantidade de imagens, com boa qualidade e informações extras referentes à imagem e ao exame. Nota-se, também, a importância das técnicas de segmentação e extração de características, especialmente na análise da textura, bem como a utilização da MVS como classificador, sendo que este apresenta resultados elevados na etapa de generalização dos resultados.

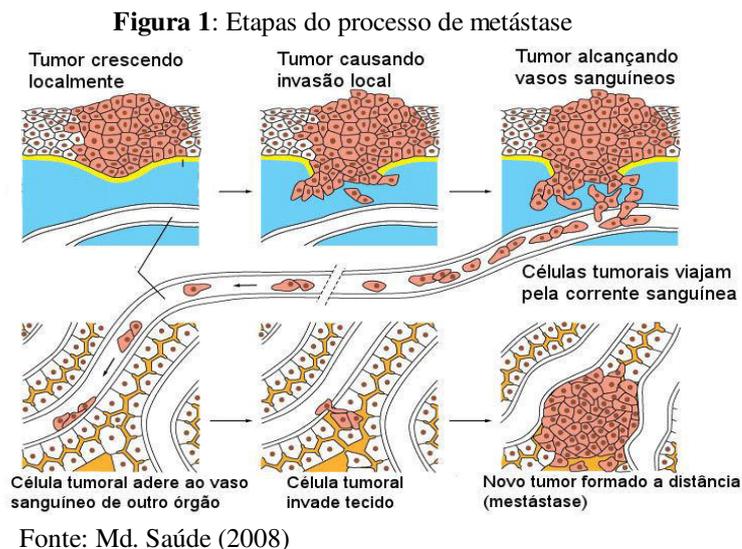
De modo geral, podem-se enumerar certos problemas encontrados em alguns dos trabalhos citados acima a exemplo de ruídos deixados na fase de retirada do fundo das mamografias, ausência de uma etapa de realce das ROIs antes da segmentação, critérios de similaridade comprometendo a formação das ROIs durante a segmentação, número elevado de regiões candidatas a massa após a segmentação e taxa de falsos positivos proeminentes. Na metodologia apresentada no presente trabalho, é proposta a utilização do algoritmo K-means, do algoritmo de crescimento de região, do filtro de Canny, do operador morfológico de erosão e da transformada de Hough para retirada do fundo da mama com ruídos e objetos indesejáveis. É usado um filtro passa-baixa, um aumento na escala de contraste e um realce com a WT para tornar mais evidente as estruturas internas das mamas. Na fase de segmentação, é utilizado o QT com dois critérios de similaridade para a formação dos clusters: a distância Euclidiana e o nível de cinza dos pixels, sendo que isso proporciona a formação de ROIs mais precisas. É utilizada uma etapa de pós-processamento com os descritores geométricos para diminuir o número de candidatos à massa após a segmentação. Por fim, com a utilização dos descritores de Haralick em conjunto com a função correlograma são extraídas características de textura significativas das ROIs, reduzindo-se, assim, as taxas de falsos positivos por imagem.

3 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta a fundamentação teórica que embasa a metodologia utilizada neste trabalho. Aborda-se o câncer de mama (Seção 3.1), o exame de mamografia (Seção 3.2), processamento de imagens (Seção 3.3), as características de texturas que descrevem as regiões suspeitas de conterem lesões (Seção 3.4.11) e (Seção 3.4.12), a classificação com a MVS (Seção 3.4.13) e as técnicas de validação dos resultados (Seção 3.4.14).

3.1 O câncer de mama

O câncer de mama é ocasionado pela reprodução frequente das células de diversas partes do corpo humano. Em certos momentos, por motivos ainda desconhecidos, algumas células começam a se reproduzir com uma velocidade maior, ocasionando o surgimento de massas celulares denominadas de neoplasias, tecido de formação nova, mas de origem patológica, que é uma denominação dada aos tumores (GIGER, 2000). Quando as neoplasias são consideradas como malignas, elas poderão se desenvolver em outras partes do corpo, ou seja, ocasionar a metástase (HADDAD, 2001). As etapas da metástase podem ser observadas na Figura 1.



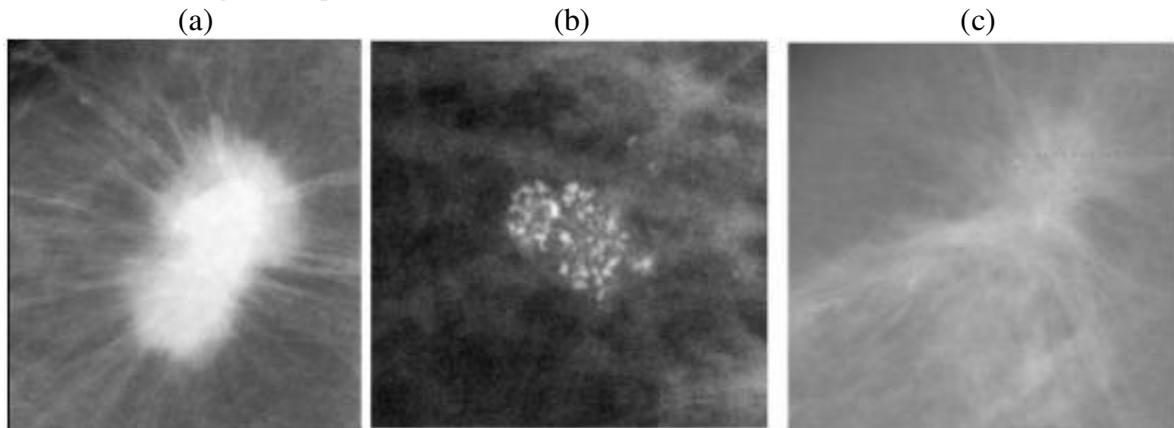
Apesar de ser considerado um câncer relativamente de bom prognóstico, se diagnosticado e tratado oportunamente, as taxas de mortalidade por câncer da mama continuam elevadas no Brasil, muito provavelmente porque a doença ainda é diagnosticada

em estgios avanados. A sobreviva media apos cinco anos na populao de pases desenvolvidos tem apresentado um discreto aumento, cerca de 85%. Entretanto, nos pases em desenvolvimento, a sobreviva fica em torno de 60% (INCA, 2012).

Um dos metodos que apresenta melhores resultados na deteco de massas imperceptveis  palpao  a mamografia, que pode detectar tumores at dois anos antes de serem clinicamente aparentes ao toque (KANE, 2003).

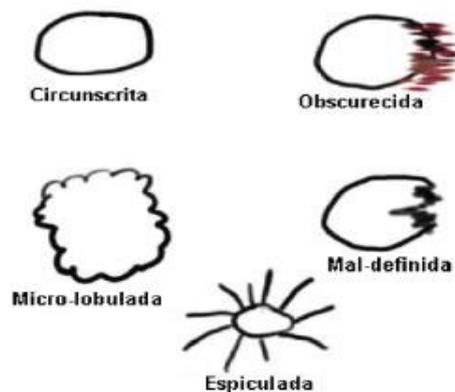
Nas anormalidades observadas atravs da mamografia esto includas as massas, as calcificaes e as distores de arquitetura (Figura 2). De acordo com Padwal (2007) as massas se apresentam como regies densas, com forma e tamanho variveis, podendo ser classificadas de acordo com suas bordas em circunscritas, microlobuladas, obscurecidas, mal definidas e espiculadas, conforme observado na Figura 3. Agora, de acordo com o seu formato, elas podero ser redondas, ovais, lobulares ou irregulares, conforme visto na Figura 4.

Figura 2: Tecidos mamrios e suas anormalidades: (a) massa espiculada; (b) micro - calcificaes agrupadas e (c) distoro de arquitetura.



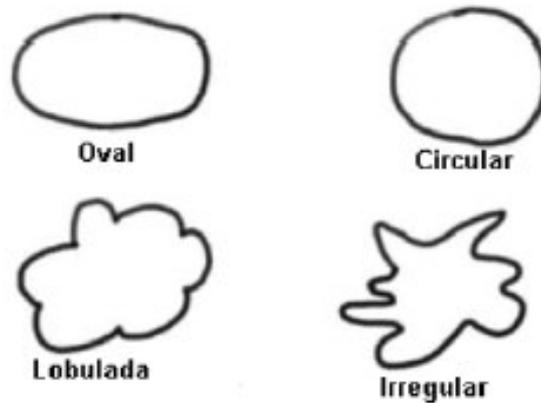
Fonte: DDSM, (2001).

Figura 3: Massas classificadas de acordo com suas bordas.



Fonte: Adaptado de Padwal (2007).

Figura 4: Massas classificadas conforme os seus formatos.



Fonte: Adaptado de Padwal (2007).

Conjuntamente aos nódulos *benignos* e *malignos* se encontram as calcificações que são depósitos de sais de cálcio nos tecidos mamários que podem ter se desenvolvido devido a processos inflamatórios, alterações degenerativas cíclicas, processos tóxicos metabólicos, traumatismos ou mesmo como resultados de processos secretores ativos de células tumorais, além de produtos de mineralização de debris necróticos (AZEVEDO, 1994).

A mamografia é uma das metodologias mais sensíveis e confiáveis para detecção precoce de nódulos não palpáveis. A descoberta precoce desse tipo de câncer, através da mamografia, ocasionará melhores resultados no tratamento (LIBERMAN; MENEL, 2002; CHAKRABARTI *et al.*, 2006).

As massas consideradas *benignas* são bem definidas e com reduzida repercussão na arquitetura vizinha da mama. Já aquelas com limites irregulares, e que se assemelham aos tecidos vizinhos, têm uma considerável possibilidade de serem *malignas* (VALLE, 2006). Todavia, o diagnóstico das massas com a mamografia não é tão fácil na maioria dos casos, exceto quando elas apresentam características de malignidade ou quando *benignas* sejam calcificações *benignas* e/ou bordas encapsuladas (KOPANS, 2000).

O nódulo mamário nem sempre produzirá uma massa perceptível: ele poderá gerar apenas uma região de distorção da arquitetura. Generalizando, o trânsito das estruturas mamárias são direcionadas para o mamilo. As alterações nesse fluxo devem ser bem analisadas, ainda que possam ser originados por elementos *benignos* (KOPANS, 2000, p. 299).

3.2 Mamografia

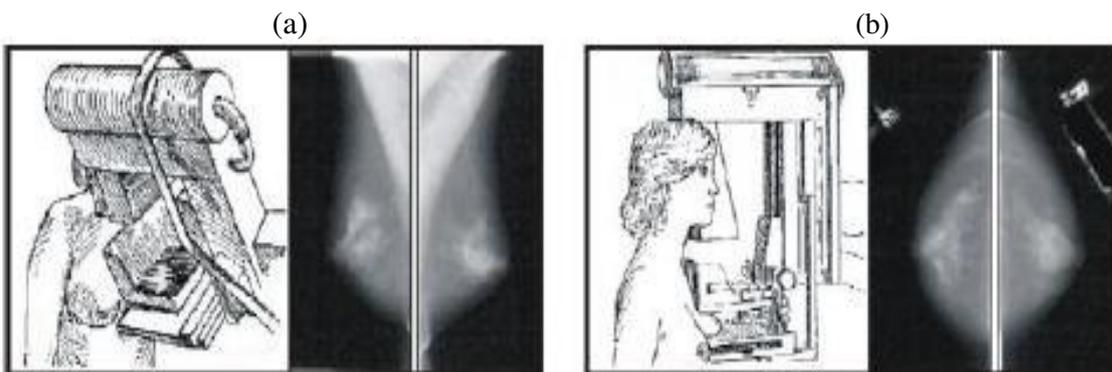
A radiologia da mama é realizada com o intuito de coletar informações sobre as diferenças existentes no tipo de estruturas dos tecidos que constituem esse órgão, logo, essa imagem forma a fonte mais importante de informações no processo diagnóstico (THIJSEN, 2003).

O objetivo desse exame é o diagnóstico imagiológico das mamas, sendo que ele possui uma atuação semelhante aos demais exames de raios-x, utilizando-se, porém, de doses mais baixas de raios X, não deixando de apresentar uma boa qualidade na imagem que possui alto contraste e resolução e baixo ruído (MAKRISHNA; GORDON, 1997).

O exame de mamografia deverá ser feito em aparelho de raios X apropriado, que chamamos de mamógrafo. Nele, a mama recebe uma compressão com o objetivo de distribuir uniformemente o tecido, evitando-se, então, a sobreposição de estruturas mamárias e diminuindo a dose de radiação recebida pelo paciente.

No exame mamográfico, normalmente, é feita uma radiografia de cada mama e são utilizadas duas formas de incidência, permitindo uma aquisição de imagens de diferentes ângulos, normalmente, a crânio-caudal (CC) e a médio-lateral oblíqua (MLO), conforme mostra a Figura 5.

Figura 5: Exames mamográficos. (a) Imagem MLO; (b) Imagem CC.



Fonte: Angelo (2007).

A visão CC mostra todo o tecido mamário, de forma que o chassi deverá ser posicionado ao nível dos limites superiores da prega inframamária, a um ângulo de 90° em relação à parede torácica, para que o raio central incida perpendicularmente ao tecido obtendo a imagem. Já a visão MLO mostra parte do músculo peitoral até a axila (MARTINAZZI, 2008). Isso é possível, pois o tubo de raios x e o chassi permanecem em ângulo reto entre si,

enquanto o raio central é angulado em área de 45° para que esse possa incidir medialmente perpendicular ao músculo peitoral da paciente, logo, o chassi será ajustado de modo que o seu topo esteja ao nível axilar (FRANK; DICKERSON, 2003).

3.3 Sistemas CAD/CADx

A atuação dos radiologistas na análise da mamografia está abaixo do ideal. De fato, é reconhecido um nível de cerca de 10% de diagnósticos falsos-negativos por falha na interpretação da mamografia (NUNES, 2001). O problema na análise desse tipo de imagem deve-se principalmente ao baixo contraste das mamografias, à possibilidade de algumas estruturas ficarem “mascaradas” na imagem e à fadiga visual por parte do radiologista (GIGER, 2000). Quando a análise da mamografia é feita por dois especialistas os resultados são bem melhores (THURFJELL *et al.*, 1994) mas certamente este não é um mecanismo possível e disponível para todos os hospitais ou clínicas radiológicas, especialmente devido aos gastos e tempo dispensados nesse tipo de procedimento.

A realização de um diagnóstico é bastante difícil, pois depende da experiência dos médicos, dados clínicos originários das imagens, sintomas dos pacientes e laudos patológicos. Logo no diagnóstico são cometidos muitos erros devido à precária qualidade das imagens, interpretações errôneas dos exames, entre outros. Isso tudo acabará por levar o paciente à realização de novos exames complementares desnecessários, invasivos, traumáticos e com alto custo financeiro.

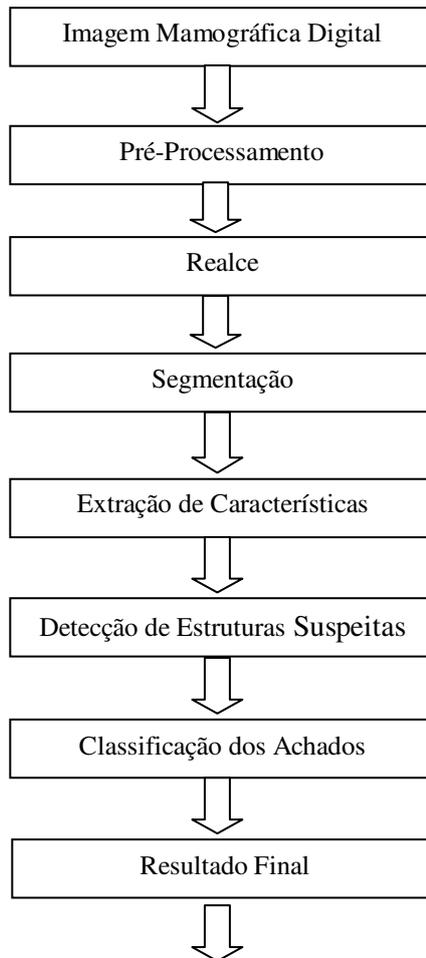
Nas últimas décadas, técnicas computacionais vêm sendo desenvolvidos com o propósito de detectar automaticamente estruturas que possam estar associadas a tumores nos exames de mamografia, visando melhorar a taxa de detecção precoce de estruturas de interesse ligadas ao câncer de mama (DENGLER *et al.*, 1993; GIGER, 2000).

Esses esquemas de processamento são conhecidos como sistemas CAD (*Computer Aided Detection*) e CADx (*Computer Aided Diagnosis*), e já estão presentes em diversos centros de diagnóstico por imagem, principalmente em países desenvolvidos, como EUA e alguns países da Europa (DENGLER *et al.*, 1993; TAYLOR *et al.*, 2004).

A detecção de lesões mamárias nos esquemas CAD geralmente começa com a segmentação da região que contém especificamente a mama na imagem (BICK *et al.*, 1995; VIEIRA *et al.*, 2001), seguida da segmentação automática das regiões de interesse (GAVRIELIDES *et al.*, 2000; GIGER; MACMAHON 2000; NISHIKAWA *et al.*, 1993). Além disso, em alguns casos, é feito um realce de contraste da região de interesse para

facilitar a visualização da lesão (BICK *et al.*, 1996; BYNG *et al.*, 1997; NUNES *et al.*, 2002). Assim, o sistema indica algumas regiões na imagem suspeitas, sendo que a responsabilidade de diagnóstico fica na responsabilidade do especialista. Na Figura 6, temos um esquema simplificado das fases dos sistemas CAD.

Figura 6: Etapas de um Sistema CAD.



Fonte: Cheng *et al.* (2003).

Atualmente, tem-se mais de 1500 CADs em uso nos EUA para auxiliar o rastreamento do câncer de mama Doi (2004). Muitos trabalhos realizados recentemente mostram uma melhor performance dos especialistas quando auxiliados pelos sistemas CAD/CADx.

As seções que se seguem, fazem uma descrição das técnicas de processamento de imagens utilizadas na metodologia CAD utilizada neste trabalho.

3.4 Processamento de imagens digitais

Por Processamento Digital de Imagens (PDI) entende-se a manipulação de uma imagem por computador de modo que a entrada e a saída do processo sejam imagens. O objetivo de se usar PDI é melhorar o aspecto visual de certas feições estruturais para o analista humano e fornecer outros subsídios para a sua interpretação, inclusive gerando produtos que possam ser posteriormente submetidos a outros processamentos (SPRING, 1996).

A análise de imagens é tipicamente baseada na forma, na textura, nos níveis de cinza ou nas cores dos objetos presentes nas imagens. Uma dificuldade inerente ao processo de análise de imagens é seu caráter multidisciplinar, quando diversos domínios de conhecimento serão comumente necessários para solucionar satisfatoriamente o problema, tais como geometria computacional, visualização científica, psicofísica, estatística, teoria da informação e muitos outros.

Na medicina, diagnósticos médicos podem ser auxiliados com o uso de imagens capturadas por raios X, tomografia computadorizada, ressonância magnética e ultrassonografia. Vários campos da medicina têm se beneficiado com o aprimoramento de diagnósticos por meio de imagens, em particular, a oncologia, a cardiologia e a ortopedia. A análise e a interpretação dessas imagens facilitam, por exemplo, a identificação de lesões ou regiões atingidas por câncer, permitindo aos médicos maior precisão e rapidez nos diagnósticos, bem como melhor planejamento dos tratamentos e das cirurgias (PEDRINI; SCHWARTZ, 2008).

As principais etapas de um PDI são aquisição de imagens, pré-processamento, segmentação, representação e descrição e reconhecimento e interpretação.

A primeira etapa do processo é a aquisição da imagem, isto é, adquirir uma imagem digital. Para fazer isso, é necessário um sensor para imageamento e a capacidade de digitalizar o sinal produzido pelo sensor. No que diz respeito às mamografias, os filmes impressos tradicionais são digitalizados por scanners especializados. Neste trabalho foi utilizada a base de mamografias digitalizadas DDSM disponível na internet (HEATH *et al.*, 1998; DDSM, 2001).

Após a obtenção da imagem digital, a próxima etapa consiste de seu pré-processamento. A função chave no pré-processamento é melhorar a imagem de forma a aumentar as chances para o sucesso dos processos seguintes. Neste trabalho, um procedimento de remoção de ruídos, baseado no algoritmo de agrupamento K-means (Seção

3.4.1) e de crescimento de regiões (Seção 3.4.2), é utilizado para remoção dos rótulos que identificam os pacientes, do fundo e das bordas dos filmes que foram digitalizados. O filtro de Canny (Seção 3.4.3), um operador morfológico de erosão (Seção 3.4.4) e a transformada de Hough (Seção 3.4.5) para a remoção do músculo peitoral em imagens MLO (SAMPAIO, 2009).

Ainda na etapa de pré-processamento das imagens foram utilizados um filtro passa-baixa (Seção 3.4.6), um aumento seletivo de contraste (Seção 3.4.7) e um realce com a WT (Seção 3.4.8).

O próximo estágio trata da segmentação que divide uma imagem de entrada em partes ou objetos constituintes. Em geral, a segmentação automática é uma das tarefas mais difíceis no processamento de imagens digitais. Por um lado, um procedimento de segmentação robusto favorecerá substancialmente a solução bem sucedida de um problema de imageamento. Por outro lado, algoritmos de segmentação fracos ou erráticos quase sempre poderão asseverar falha no processamento. Neste trabalho foi utilizado o Quality Threshold Clustering (Seção 3.4.9) no processo de segmentação das imagens mamográficas.

Após a segmentação, nesta metodologia, foi inserida uma etapa de pós-processamento com o intuito de reduzir os clusters candidatos à massa, sendo que para isso foi utilizado os descritores geométricos de excentricidade, circularidade e compacidade.

Na representação, estruturas adequadas deverão ser utilizadas para armazenar e manipular os objetos de interesse extraídos da imagem. O processo de descrição visa à extração de características ou propriedades que possam ser utilizadas na discriminação entre classes de objetos. Essas características são, em geral, descritas por atributos numéricos que formam um vetor de características. Nesta metodologia as regiões de interesse são descritas através da textura com os Descritores de Haralick (Seção 3.4.10.2) e a função de Correlograma (Seção 3.4.11.1).

O último estágio envolverá reconhecimento e interpretação. Reconhecimento é o processo que atribui um rótulo a um objeto, baseado na informação fornecida pelo seu descritor. A interpretação envolve a atribuição de significado a um conjunto de objetos reconhecidos. Neste trabalho, utilizou-se a MVS (Seção 3.4.12) para o reconhecimento dos padrões existentes nas características extraídas das texturas das regiões de interesse e distingui-las em *massas* ou *não-massas*.

As subseções seguintes mostram as técnicas de processamento de imagens utilizadas na metodologia deste trabalho.

3.4.1 K-means

O K-Means é uma heurística de agrupamento não hierárquico que busca minimizar a distância dos elementos a um conjunto de k centros dado por $c=\{x_1,x_2,\dots,x_k\}$ de forma iterativa. A distância entre um ponto p_i e um conjunto de clusters, dada por $d(p_i, c)$, é definida como sendo a distância do ponto ao centro mais próximo dele. A função a ser minimizada pode ser vista na Equação 1 (HOUGH, 1962):

$$d(P, \chi) = \frac{1}{n} \sum_{i=1}^n d(p_i, \chi)^2 \quad (1)$$

O algoritmo dependerá de um parâmetro (k = número de *clusters*) definido de forma *ad hoc* pelo usuário. Isto costuma ser um problema, tendo em vista que normalmente não se sabe quantos clusters existem *a priori*.

O algoritmo do K-Means pode ser descrito da seguinte maneira:

1. Escolher k distintos valores para centros dos grupos (possivelmente, de forma estocástica).
2. Associar cada ponto ao centro mais próximo.
3. Recalcular o centro de cada grupo.
4. Repetir os passos 2-3 até nenhum elemento mudar de grupo.

Este algoritmo é extremamente veloz, geralmente convergindo em poucas iterações para uma configuração estável, na qual nenhum elemento está designado para um cluster cujo centro não lhe seja o mais próximo.

Ele tenderá a convergir para um mínimo da função de energia definida acima. Um eventual problema é que essa condição enfatizará a questão da homogeneidade e ignorará a importante questão da boa separação dos clusters. Isto poderá causar uma má separação dos conjuntos no caso de uma má inicialização dos centros, inicialização esta que é feita de forma arbitrária (estocástica) no início da execução.

Neste trabalho, o algoritmo de K-means foi utilizado para remoção de ruídos da mamografia, isolando a mama da imagem completa.

3.4.2 Crescimento de região

O método de crescimento de regiões procura por regiões que contenham pixels semelhantes. Ele inicia escolhendo um pixel ou grupo de pixels denominados sementes.

Sendo que a escolha dessas sementes poderá ser tanto automática quanto manual, devendo ser feita no local da estrutura que se pretende segmentar.

O passo seguinte será fazer o teste dos pixels vizinhos, adicionando-os ao grupo para o crescimento da região. Os novos pixels serão adicionados de acordo com a semelhança sobre um critério de uniformidade, também chamado teste de homogeneidade. O procedimento repetir-se-á até não ser possível adicionar nenhum novo pixel. O objeto será, então, representado por todos os pixels aceitos durante o procedimento de crescimento da região (BANKMAN, 2000).

Um teste de semelhança é a comparação da intensidade do pixel a ser testado e o valor da intensidade média da região. Se a diferença for menor que certo valor estipulado, o pixel será inserido na região, caso contrário, ele será adicionado na região de fronteira.

O crescimento da região dependerá fortemente do critério de similaridade. Se for escolhido de forma errada, poderá ocasionar a fragmentação da região de interesse ou junção de regiões diferentes que não caracterizam a estrutura de interesse (FATIMA *et al.*, 2007). Outra dificuldade desse método é que, caso o processo seja erroneamente conduzido para pontos distintos, poderá levar a diferentes crescimentos de regiões. A vantagem deste método está no fato de ser capaz de segmentar acertadamente as regiões que têm propriedades iguais mesmo estando espacialmente afastadas.

No presente trabalho o crescimento de região é usado para remover os rótulos de marcação do especialista, o fundo da mamografia e para unir os *clusters* que pertencem a uma mesma massa, que eventualmente vieram a ser divididos na segmentação, na fase de detecção das massas.

3.4.3 Filtro de Canny

No filtro de Canny a imagem é suavizada com as derivadas de primeira ordem do filtro Gaussiano na direção do gradiente local seguido pela detecção de bordas por dois limiares (CANNY, 1986).

Ele é um filtro de convolução que usa a primeira derivada e também é um operador não linear. Ele suaviza o ruído e localiza as bordas, combinando um operador diferencial com um filtro Gaussiano. Os pontos de máximos depois da convolução indicarão as bordas na imagem. Este processo pode ser realizado através do uso de uma função Gaussiana em duas dimensões, ou uma função 1D na direção de x e depois na direção y . As formas das máscaras Gaussianas dependem da escolha do desvio padrão usado, ou seja, o

valor de σ na equação da função Gaussiana. A função Gaussiana unidimensional é expressa por

$$G(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2}{2\sigma^2}} \quad (2)$$

De modo que sua primeira derivada é dada por

$$G'(x) = \frac{-x}{\sqrt{2\pi\sigma^3}} e^{-\frac{x^2}{2\sigma^2}} \quad (3)$$

A ideia do filtro de Canny para detecção de bordas é usar $G'(x)$. Fazendo a operação de convolução da imagem com $G'(x)$, obtém-se uma imagem I , que mostrará as bordas, mesmo na presença de ruído. A distribuição Gaussiana com covariância igual a zero é dada pela Equação 4:

$$G(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} e^{-\frac{x^2}{2\sigma_x^2} - \frac{y^2}{2\sigma_y^2}} \quad (4)$$

As Gaussianas 2D dependerão da escolha dos desvios padrões nas duas direções, sendo geralmente usados em imagens com ambos σ iguais, ou seja: o mesmo valor de σ em x e y , $\sigma = \sigma_x = \sigma_y$, na equação da função Gaussiana.

Neste trabalho o filtro de Canny (1986) foi utilizado para localizar linhas que possivelmente pertençam à borda do músculo peitoral das imagens do tipo MLO.

3.4.4 Morfologia matemática

Morfologia matemática, originalmente desenvolvida em 1964 por Georges Matheron e Jean Serra na École des Mines de Paris, é uma ferramenta que se concentra nas estruturas geométricas da imagem para extração de componentes que são úteis para representação e descrição da forma de uma região, como fronteiras e esqueletos. Algumas operações matemáticas podem ser aplicadas a conjuntos de pixels, a fim de intensificar aspectos das formas tal que eles possam ser contados ou reconhecidos (MELLO, 2008).

Essa técnica, baseada na teoria dos conjuntos, oferece uma abordagem unificada e

poderosa para inúmeros problemas de processamento de imagens (GONZALES; WOODS, 1992). Os conjuntos em Morfologia Matemática representam as formas dos objetos em uma imagem. Por exemplo, o conjunto de todos os pixels pretos em uma imagem binária é uma descrição completa dessa imagem.

As operações na Morfologia Matemática são realizadas através de operadores elementares tais como a dilatação e a erosão. As técnicas morfológicas para pré e pós-processamento, como filtragem morfológica, afinamento e poda (“*pruning*”) também são muito exploradas atualmente (VIEIRA; MELO, 2004).

3.4.4.1 Elemento estruturante

O elemento estruturante é um conjunto definido e conhecido (forma e tamanho), que é comparado, a partir de uma transformação, ao conjunto desconhecido da imagem. Poderá assumir várias formas e sua origem poderá ser definida em qualquer ponto (VIEIRA; MELO, 2004). Para o caso de processamento de imagens em tons de cinza, os elementos do elemento estruturante poderão assumir valores entre 0 e 255. Cumpre ressaltar que não necessariamente o elemento estruturante é uma matriz retangular ou quadrada.

3.4.4.2 Processo de erosão de imagens

A imagem resultante da aplicação de uma erosão não somente aparentará ser mais clara que a original, mas os tamanhos das áreas mais escuras serão reduzidos. Isso significa que o algoritmo para aplicação de erosão em imagens segue os seguintes passos:

1. O elemento estruturante é posicionado no início da imagem a ser aplicada a erosão.
2. É feita a comparação da subtração das intensidades dos pixels da imagem original com as intensidades dos pixels correspondentes da matriz do elemento estruturante.
3. O pixel correspondente da imagem de saída terá a intensidade da menor subtração desta comparação. Caso a menor subtração seja menor que zero o valor assumido para a intensidade do pixel correspondente será zero.
4. A matriz do elemento estruturante é posicionada no elemento seguinte da matriz que representa a imagem original, retornando-se ao passo de número 2. Caso o último elemento da matriz da imagem original já tenha sido visitado

pela matriz do elemento estruturante, o processo de erosão estará concluído.

.O operador de erosão foi utilizado neste trabalho com o intuito de serem removidas todas as bordas que não estejam na mesma direção do músculo peitoral.

3.4.5 Transformada de Hough

A Transformada de Hough foi desenvolvida por Hough (1962) no início dos anos 60. É uma técnica de reconhecimento, em imagens digitais, para que sejam facilmente parametrizadas, isto é, que possuam uma equação com fórmula conhecida, tais como retas, círculos segundo Kimme et al. (1975) e elipses (LEI; WONG, 1993) (TSUJI; MATSUMOTO, 1978), entre outras. A partir da primeira publicação, vieram muitos outros trabalhos melhorando, otimizando (XU; OJA, 1993) (ILLINGWORTH; KITTLER, 1988) (LEAVERS, 1993) e até aplicando a transformada a formas generalizadas (BALLARS, 1981) (FERNANDES; OLIVEIRA, 2012).

Para a aplicação desta transformada, normalmente será realizado um pré-processamento na imagem com o objetivo de identificar claramente os contornos dos elementos que a compõem.

A ideia da transformada de Hough é transformar a imagem do espaço digital (x, y) para uma representação na forma dos parâmetros descritos pela curva que se deseja encontrar na imagem. Essa transformação é aplicada de modo que todos os pontos pertencentes a uma mesma curva sejam mapeados em um único ponto no espaço dos parâmetros da curva procurada. Para isto, o espaço dos parâmetros é discretizado e representado na forma de uma matriz de inteiros, onde cada posição da matriz corresponderá a um intervalo no espaço real dos parâmetros. Cada ponto da imagem, que satisfizer a equação da forma paramétrica procurada, incrementa de uma unidade o contador correspondente a sua posição, na representação discretizada (matriz).

O contador que tiver, no final do processo, o valor mais alto, corresponderá aos parâmetros da curva mais aparente que esteja descrita na imagem.

3.4.5.1 Identificação das retas

Dado um ponto (x, y) do R ou Z , a equação reduzida das retas que passam por este ponto é dado por:

$$y = mx + g \quad (5)$$

onde m corresponde ao coeficiente angular da reta e g é o valor do ponto onde há interseção da reta com o eixo y . O plano mg é o espaço dos parâmetros onde pontos no espaço da imagem (x, y) são representados como retas, e o ponto de interseção dessas retas representa os valores m e g que identificam uma reta composta pelos mesmos parâmetros no espaço da imagem (x, y) (HOUGH, 1962).

Todos os pontos pertencentes a uma única reta interceptam-se em um único ponto que tem como coordenadas os parâmetros (m, g) da reta a ser identificada.

Um problema, quando essa equação de retas é usada, ocorre quando se deseja identificar retas verticais, pois, neste caso, o coeficiente angular tenderá ao infinito. Para viabilizar a técnica, é proposta a utilização da equação da reta na forma polar, ou equação normal da reta:

$$\rho = x \cos \theta + y \sin \theta \quad (6)$$

onde ρ é a distância da reta à origem e θ é o ângulo entre o eixo x e a normal desta reta, considerando positivo o sentido horário (DUDA; HART, 1972).

Utilizando a equação da reta na forma polar. Cada ponto (x, y) é representado por um conjunto de pontos (ρ, θ) que definem uma curva no espaço de parâmetros. O plano (ρ, θ) define o espaço dos parâmetros. Cada ponto $P(x, y)$ de uma reta $R(\rho, \theta)$ é representado por uma senoide $S(\rho, \theta)$ no espaço dos parâmetros. A interseção das senoides no plano (ρ, θ) representa o valor ρ e θ de uma reta no espaço da imagem (x, y) . Todos os pontos pertencentes à mesma reta interceptam-se em um único ponto (ρ, θ) no espaço dos parâmetros.

A Transformada de Hough foi usada nesta metodologia para detectar a reta que cotorna o músculo peitoral da imagem MLO auxiliando assim a retirada do mesmo.

3.4.6 Filtro passa-baixa

O efeito de um filtro passa-baixa é o de suavização da imagem, uma vez que as frequências altas que correspondem às transições abruptas são atenuadas. A suavização tenderá, também, pelas mesmas razões, a minimizar o efeito do ruído em imagens. Por outro lado, devido ao borramento causado pela filtragem passa-baixa, detalhes finos poderão ser removidos da imagem (PEDRINI; SCHWARTZ, 2008).

Os filtros cujas máscaras possuem seus coeficientes iguais a um com o resultado da convolução destas, sobre as áreas a serem filtradas da imagem, dividido por um fator de

normalização (soma dos coeficientes da máscara) são denominados filtros passa baixa da média. Nele cada pixel é substituído pelo valor médio dos seus vizinhos.

Neste trabalho foi utilizado o Filtro Passa Baixa da Média com uma máscara 3x3 com o intuito de realizar uma suavização da imagem, ou seja, uma atenuação dos pixels de altas frequências retirando as mudanças abruptas dos níveis de cinzas dos pixels pertencentes a uma mesma região, tornando-os mais homogêneos. Logo, quanto mais for uniforme, em relação aos níveis de cinza dos pixels, a região a ser tratada pela clusterização QT melhores serão os resultados da segmentação.

3.4.7 Aumento seletivo de contraste

O objetivo das transformações de contraste é melhorar a qualidade das imagens sob critérios subjetivos ao sistema visual humano, tornando mais fácil a percepção de informações contidas nas imagens.

O intervalo de contraste é a diferença entre os valores de intensidade máximo e mínimo que uma imagem pode assumir. Quando uma imagem não ocupar todo o intervalo de cinza possível, poder-se-á ampliar o intervalo de contraste. Isso pode ser feito por meio de um mapeamento das variações de contraste dentro do intervalo de níveis de cinza $[Z_1, Z_k]$ da imagem original para a variação máxima do dispositivo de visualização, geralmente, no intervalo $[0, 255]$. Essa transformação é realizada por uma função de mapeamento, tal que cada valor de cinza na imagem original seja mapeado para um novo valor de cinza (PEDRINI; SCHWARTZ, 2008).

Uma maneira de fazer esta transformação da escala de cinzas pode ser observada na Equação 7.

$$z = \left(\frac{z_k - z_1}{b - a} \right) (c - a) + z_1 \quad (7)$$

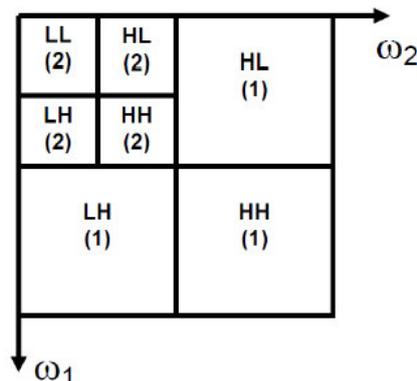
onde a é o nível de cinza mínimo da imagem original, b é o nível de cinza máximo da imagem original, c é o nível de cinza do pixel da imagem original e z é o nível de cinza do pixel original após o realce do contraste.

Neste trabalho, o realce de contraste foi realizado com o intuito de tornar mais nítidas as regiões de interesse contidas nas mamografias.

3.4.8 Realce com a transformada de wavelet

A transformada de *wavelet* discreta (DWT) bidimensional é considerada como uma filtragem em sub-bandas de frequências (VIDAURRAZAGA, *et al.*, 2000; TAUBMAN; MARCELLIN, 2002). Ou seja, a imagem é tratada por um banco de filtros direcionais resultando em um conjunto de coeficientes agrupados por sub-bandas de frequências conforme observado na Figura 7. Esses coeficientes significam a contribuição de cada sub-banda para formação da imagem. Cumpre lembrar que esses coeficientes estão distribuídos no domínio espacial, em cada sub-banda. Os coeficientes de baixas frequências são responsáveis pela formação da imagem de aproximação e os coeficientes de frequências altas são responsáveis pelos detalhes e pelo ruído.

Figura 7: Wavelet decomposta em dois níveis com quatro sub-bandas cada um e seus coeficientes.



Na Figura 7, estão representados sete grupos de coeficientes originados a partir da decomposição da wavelet em dois níveis. Cada grupo foi nomeado por duas letras e um número, onde a primeira letra corresponde à faixa de frequências horizontais, a segunda letra corresponde à faixa de frequências verticais e o número corresponde ao nível de decomposição wavelet. A letra L (“Low”) representa a faixa de baixas frequências e a letra H (“High”) representa a faixa de altas frequências. As setas ω_1 e ω_2 indicam o sentido de crescimento das frequências nas sub-bandas. Porém, ressalte-se, novamente, que cada uma delas contém uma subimagem no domínio espacial (VALLE, 2006).

Há métodos de realce no domínio da transformada de *wavelet* que redistribuem os coeficientes utilizando funções lineares (VIDAURRAZAGA *et al.*, 2000). Os coeficientes da imagem original são mapeados através das funções, a cada sub-banda, em um novo conjunto de coeficientes. Sendo que a imagem realçada é obtida aplicando a DWT inversa. Estes

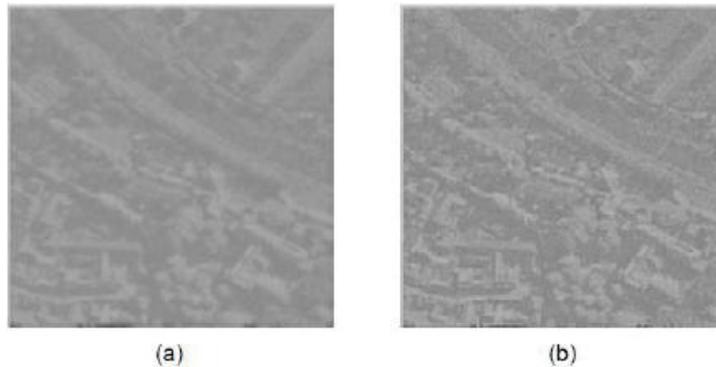
métodos tendem a aplicar ganho aos coeficientes de altas frequências. O ganho utilizado pela função em cada coeficiente é controlado pelos parâmetros que ajustam esses métodos, que em um número significativo serão ajustados no decorrer de cada nível da decomposição.

Um exemplo de uma função linear utilizada em Vidaurrazaga *et al.* (2000) para alterar os coeficientes DWT esta expresso na Equação 8:

$$W_{out\ i,j} = K \cdot W_{in} \quad (8)$$

onde i e j são os índices que indicam as posições dos coeficientes nas sub-bandas, $W_{in\ i,j}$ são os coeficientes wavelet da imagem original, $W_{out\ i,j}$ são os coeficientes DWT realçados e K é o parâmetro responsável pelo ajuste do método, que está na dependência do nível de decomposição, que neste caso é o próprio ganho. O valor desse parâmetro decresce a uma taxa de $K^{0,5}$ com o nível de decomposição wavelet. Na Figura 8 temos um exemplo de realce com a função linear.

Figura 8: Realce com DWT: (a) imagem original, (b) imagem realçada com função linear.



Nesta metodologia, foi realizado um realce, com a transformada de *wavelet*, nas imagens resultantes do aumento da escala de contraste com o intuito de evidenciar ainda mais as regiões de interesse.

3.4.9 Clusterização com quality threshold (QT)

O algoritmo de clusterização Quality Threshold (XU; WUNSCH, 1999; GORDON, 1999) é um método de agrupamento de dados alternativo, proposto inicialmente para a clusterização de genes do cromossomo humano. Enquanto ele requiser maior poder computacional para atingir o resultado, o seu funcionamento não depende da pré-determinação do número de *clusters*, sempre retornando o mínimo global da solução.

O algoritmo de clusterização *QT* é apresentado a seguir:

1. Inicialmente, é necessário escolher o diâmetro máximo para cada *cluster* de acordo com o tamanho das regiões que se quer segmentar.
2. Para cada amostra, encontrar o *cluster*-candidato mais apropriado, considerando-se a distância do ponto atual até o ponto mais próximo do *cluster*, repetindo-se esse procedimento para todos os *clusters* que estão dentro do limite pré-estabelecido pelo diâmetro do passo 1.
3. Salvar o *cluster*-candidato que tem o maior número de amostras como sendo o primeiro *cluster* verdadeiro, removendo todos os pontos que pertencem a ele das iterações futuras.
4. Repetir o algoritmo com o número de pontos reduzidos, até que todas as amostras sejam alocados nos *clusters*.

O valor de proximidade entre uma amostra e um *cluster* é calculado considerando a distância máxima entre ela e todos os pontos pertencentes ao *cluster*.

O modelo resulta em uma clusterização mais precisa, uma vez que um número adequado de *clusters* é alocado para cada caso. O custo computacional do modelo, entretanto, é significativamente maior de que o do modelo de k-médias e c-médias (DODONOV; MELLO, 2008).

O algoritmo de clusterização QT foi utilizado neste trabalho para realizar a segmentação da imagem pré-processada retornando *clusters* candidatos a *massas* e *não-massas*.

3.4.10 Medidas geométricas

As medidas geométricas podem ser utilizadas como informações a respeito da circularidade dos objetos, sendo que isso se torna importante à medida que a maioria dos nódulos *benignos* e *malignos* (espiculares) estão associados à forma geométrica circular (RANGARAJ *et al.*, 1997).

Entre os vários parâmetros utilizados como descritores da variação espacial do objeto podemos destacar (BÄSSMAN; KREYSS, 1998; GONZALES; WOODS, 2000): área, perímetro, compacidade, descritores de *Fourier*, excentricidade descritores baseados em momentos, com principal representante os sete momentos invariantes (*Hu Moments*), e curvatura (RANGAYYAN, 1997).

O objeto no qual se realizará o cálculo das medidas geométricas é binarizado, isto é, não serão levados em consideração seus níveis de cinza. Somente propriedades como área e

perímetro serão consideradas nos cálculos, pois os descritores geométricos utilizados, nesta metodologia, só precisam dessas medidas para serem calculados.

Os descritores utilizados neste trabalho foram: a excentricidade, a circularidade, a compacidade e a densidade circular.

3.4.10.1 Excentricidade (E)

É a razão entre o *eixo maior* (comprimento do maior segmento de reta que pode ser traçado ao longo de um objeto) e o *eixo menor* (comprimento do maior segmento de reta perpendicular ao *eixo maior*) (BRAZ JÚNIOR *et al.*, 2006).

Uma outra maneira de calcular a excentricidade é por meio dos momentos centrais, conforme observado na Equação 9.

$$E = \frac{(\mu_{02} - \mu_{20}) + 4\mu_{11}}{A} \quad (9)$$

sendo que A é a área do objeto e μ os momentos centrais que são obtidos através da Equação 10.

$$\mu_{pq} = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} (x - \bar{x})^p (y - \bar{y})^q \quad (10)$$

Considerando que $p+q > 1$ e (\bar{x}, \bar{y}) é o centro de gravidade do objeto analisado.

3.4.10.2 Circularidade (C)

Circularidade traduz a semelhança de um objeto em relação a uma circunferência. O objeto é tão mais circular quanto mais próximo da unidade for o valor da sua circularidade. A Equação 11 define a circularidade.

$$C = \frac{4\pi A}{(P_{convexo})^2} \quad (11)$$

onde A é a área do objeto analisado e $P_{convexo}$ é o perímetro convexo (ZIBREIRA, 2000).

3.4.10.3 Compacidade (C_o)

Compacidade mostra o quão denso é um objeto ao ser comparado com um objeto perfeitamente denso – o círculo (SCHOUTEN, 2003). Ela é definida pela Equação 12.

$$C_o = \frac{P^2}{4\pi A} \quad (12)$$

onde A é a área do objeto e P é o seu perímetro.

3.4.10.4 Densidade circular (D_c)

No cálculo da densidade circular é utilizado um círculo, que é uma figura que não varia em sua rotação, para aferir o percentual do círculo que também corresponde ao objeto (SOUSA *et al.*, 2007). Sendo que isso é feito com a utilização de um círculo que possui a mesma área do objeto e com o seu centro de massa posicionado no mesmo local do centro de massa do objeto. Através da Equação 13 pode-se observar essa medida.

$$D_c = \frac{100n}{A} \quad (13)$$

onde A é a área do objeto e n é a quantidade de pontos que pertencem ao objeto e ao círculo que possui um raio estimado R (Equação 14).

$$R_e = \sqrt{\frac{A}{\pi}} \quad (14)$$

Nesta metodologia esses descritores geométricos foram utilizados com o intuito de retirar os clusters que apresentavam deformidades não condizentes com o formato das massas e assim reduzindo os candidatos a massa para a etapa de extração de características.

3.4.11 Descritores de textura

Em Gonzalez e Woods (2000) foi referida a existência de três principais abordagens para se descrever texturas: a abordagem espectral, estrutural e estatística. A abordagem espectral diz respeito a propriedades baseadas no espectro de Fourier, onde pode ser detectada a existência de padrões periódicos ou semiperiódicos (KULKARNI, 1995). A

abordagem estrutural representa textura como sendo formada pela repetição de padrões que obedecem alguma regra de posicionamento para a sua geração (BALLARD; BROWN, 1982). Já na abordagem estatística, medidas são utilizadas para descrever texturas. Esta abordagem é geralmente recomendada para texturas que não apresentam boa regularidade (BALLARD; BROWN, 1982).

A abordagem estatística de descrição de texturas considera o relacionamento, a distribuição dos tons de cinza e o inter-relacionamento entre eles através do cálculo das matrizes de co-ocorrência.

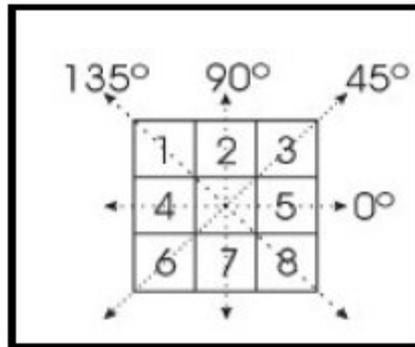
3.4.11.1 Matriz de co-ocorrência

A matriz de co-ocorrência de níveis de cinza leva em consideração a posição de pixels que possuem níveis de cinza. Uma matriz de co-ocorrência é uma tabulação sobre o número de combinações distintas de valores de intensidade que ocorrem em uma imagem (SCHWARTZ; PEDRINI, 2003).

Essa matriz considera a relação entre dois pixels por vez, um chamado de pixel referência e o outro de pixel vizinho. O pixel vizinho escolhido pode ser vizinho em qualquer direção: por exemplo, a leste (direita), a oeste (esquerda), a norte (acima), a sul (abaixo), ou na diagonal, ou seja: a nordeste, noroeste, sudoeste e sudeste de cada pixel referência. Também a vizinhança não precisa ser exatamente de 1 pixel: poderá ser de 2, 3, ou qualquer valor. Cada pixel dentro da imagem torna-se o pixel referência, iniciando no canto superior esquerdo e procedendo até o inferior direito. Existem alguns casos particulares, como, por exemplo, os pixels situados na margem direita que não têm vizinhos da direita.

A co-ocorrência, na sua forma geral, pode ser especificada por uma matriz de frequências relativas $P(i, j; d, \theta)$, na qual dois elementos de textura vizinhos, separados por uma distância d em uma orientação θ ocorrem na imagem, um com propriedade i e o outro com propriedade j . Instanciando essa definição para co-ocorrência de níveis de cinza, os elementos de textura são pixels e as propriedades são os níveis de cinza. Por exemplo, para um relacionamento com um ângulo $\theta = 0^\circ$, e vizinhança considerado 1 pixel, tem-se: $P(i, j; 1, 0)$. Em outras palavras, a matriz de co-ocorrência pode ser definida como $P(i, j, d, \theta)$, onde i e j são pixels vizinhos de acordo com a distância d . Esta distância entre os pixels i e j é analisada de acordo com uma direção θ . Os valores possíveis para θ são os ângulos de 0° , 45° , 90° e 135° em relação ao plano horizontal do pixel de referência conforme observado na Figura 9.

Figura 9: Ângulos para o cálculo na matriz de co-ocorrência.



Desta forma, a matriz (obrigatoriamente quadrada) de co-ocorrência, representa em cada elemento a_{ij} o número de vezes em que ocorreu uma transição do nível de cinza Z_i para Z_j considerando-se a distância d entre os pixels vizinhos i e j na direção θ .

Essas matrizes podem ser normalizadas através da divisão de cada entrada da matriz pelo número total de pares de pontos de pixels vizinhos que satisfaçam $P(i, j, d, \theta)$. Desta forma, cada valor corresponde a probabilidades de uma transição, da forma especificada θ , do nível de cinza i para o nível de cinza j , com uma distância d pixels (VASCONCELOS, 2008).

3.4.11.2 Descritores de Haralick

Foi proposto em (HARALICK *et al.*, 1973) um método para extração de características de texturas baseado na relação espacial existentes entre os níveis de cinza da imagem, calculando as chamadas matrizes de co-ocorrência e, a partir delas, determinaram 14 parâmetros estatísticos que caracterizam as texturas. Devido a sua simplicidade e eficácia, este método tornou-se bastante popular na classificação de texturas, sendo considerado por muitos autores como “o método de referência” em relação aos quais os outros métodos são comparados. Segundo (BARALDI; PARMIGGIANI, 1995), dentre as 14 medidas estatísticas propostas originalmente, apenas seis apresentam maior relevância: o segundo momento angular, o contraste, a correlação, a entropia, a variância e a homogeneidade.

3.4.11.2.1 Segundo momento angular

Mede a uniformidade da textura, a saber, a quantidade de repetições de pares de pixels. Essa medida terá valores altos quando os valores da matriz de co-ocorrência estiverem concentrados, ou seja, quando houver grande repetição na variação dos níveis de cinza. Ele

pode ser observado na Equação 15.

$$ASM = \sum_i \sum_j \{p(i,j)\}^2 \quad (15)$$

onde $p(i, j)$ é o pixel da matriz de co-ocorrência e i e j são os seus respectivos índices.

3.4.11.2.2 Contraste

É uma medida do contraste ou da quantidade de variações locais presentes em uma imagem. Se em uma imagem existe maior quantidade de variações locais, os valores de contraste se apresentarão mais elevados do que uma imagem com menos variações locais. Isso poderá ser observado na Equação 16.

$$Con = \sum_{n=0}^{Ng-1} n^2 \left\{ \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i,j) \right\}_{|i-j|=n} \quad (16)$$

onde Ng é a quantidade de níveis de cinza de uma imagem.

3.4.11.2.3 Correlação

É uma medida das dependências lineares dos níveis de cinza em uma imagem conforme a Equação 17,

$$Corr = \frac{\sum_i \sum_j (ij)p(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (17)$$

onde μ_x e μ_y são as médias e σ_x e σ_y são os desvios padrões.

3.4.11.2.4 Entropia

A entropia mede a desordem em uma imagem. Quando a imagem não apresenta textura uniforme, os valores da entropia tenderão a ser muito baixos. O cálculo da entropia pode ser visto na Equação 18.

$$Ent = - \sum_i \sum_j p(i,j) \log(p(i,j)) \quad (18)$$

3.4.11.2.5 Variância

Essa é uma medida da heterogeneidade da textura. O valor da variância aumenta quando os valores dos tons de cinza diferem de sua média. Observe-se isso na Equação 19.

$$Var = \sum_i \sum_j (i - \mu)^2 p(i, j) \quad (19)$$

onde

$$\mu = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} i p(i, j).$$

3.4.11.2.6 Homogeneidade

Mede a homogeneidade de uma da matriz de co-ocorrência. A homogeneidade está inversamente relacionada com o contraste. Ela pode ser observada na Equação 20.

$$Hom = \sum_i \sum_j \frac{p(i, j)}{1 + (i - j)^2} \quad (20)$$

3.4.12 Função geoestatística

O avanço inicial significativo na caracterização da variabilidade espacial surgiu nas minas de ouro da África do Sul, quando D. G. Krieger, em 1951, fez a demonstração de como a variância de um parâmetro medido estava constantemente dependente da distância entre as amostras (VIEIRA *et al.* 1988). Contudo, um passo ainda mais significativo foi dado por G. Matheron e sua equipe, em Fontainebleau, em 1963, ao publicar o tratado “Teoria das Variáveis Regionalizadas”. Ao aplicar essa teoria na Geologia e na Mineração ela ficou conhecida como Geoestatística (CLARK, 1979).

A Geoestatística pode ser vista como um grande ramo da estatística espacial que estuda a relação de uma variável regionalizada com ela mesma numa outra posição (CRESSIE, 1993). Ela também espera que, na média, as amostras próximas no tempo e no espaço sejam mais similares entre si do que as que estiverem distantes (ISAACS; SRIVASTAVA 1990).

A variabilidade espacial com dependência, segundo Warrick *et al.* (1986), é comumente descrita através de correlogramas ou variogramas, que definem o grau de dependência e o alcance ou domínio de cada amostragem ou medida (REICHARDT *et al.*,

1986).

Com relação à estatística, dois componentes principais, associados a pixels, podem descrever a textura: a autocorrelação espacial e a variabilidade. Elas fazem a descrição através do grau de associação espacial presente dentro dos elementos geograficamente referenciados da imagem. A correlação dos pixels, considerados pontos independentes, pode ser analisada com medidas como o correlograma.

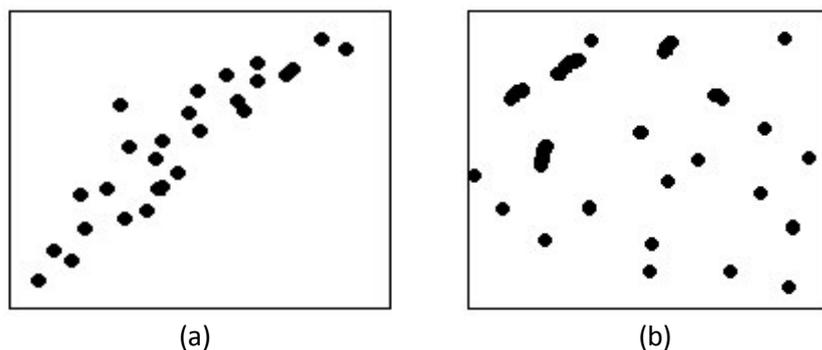
3.4.12.1 Correlograma

A função de correlograma ou função de correlação é a relação do coeficiente de correlação de um diagrama de dispersão e uma distância h . Esta função pode ser resumida como sendo a versão normalizada da função covariograma. Os coeficientes de correlação estão na faixa de -1 a 1.

O correlograma apresenta valores altos para distâncias pequenas, sendo que os mesmos tenderão a descrever à medida que a distância aumenta, ou seja: espera-se que a correlação seja alta para unidades que estão próximas umas das outras e que tenda a zero quando a distância entre as unidades aumenta.

Na Figura 10, temos exemplos de amostras correlacionadas e amostras não-correlacionadas.

Figura 10: Correlograma: (a) amostras correlacionadas, (b) amostras não-correlacionadas.

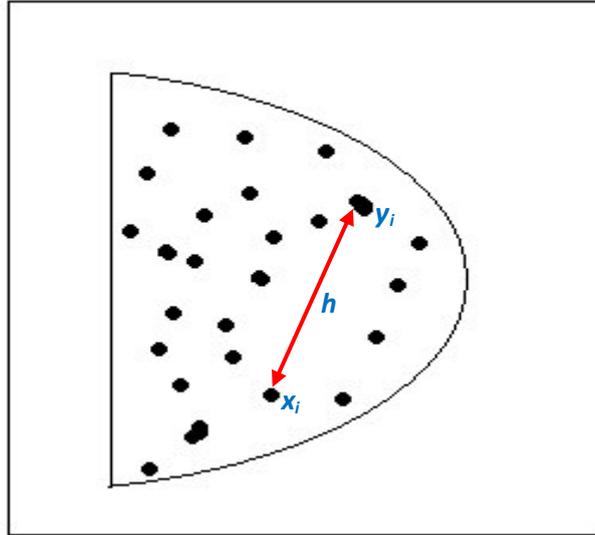


A função correlograma é definida pela Equação 21:

$$\rho(h) = \frac{\frac{1}{N(h)} \sum_{i=1}^{N(h)} x_i y_i - m_{-h} m_{+h}}{\sigma_{-h} \sigma_{+h}} \quad (21)$$

onde x_i e y_i , relacionados a textura de imagens, são os pixels de origem e extremidade respectivamente, h é a distância entre o pixel origem e o pixel extremidade e $N(h)$ é o número de pares de pixels na distância h . Na Figura 11, podemos observar a demonstração desses parâmetros.

Figura 11: Ilustração dos pixels de origem (x_i), pixels de extremidade (y_i) e a distância h entre x_i e y_i



Ainda em relação à equação do correlograma m_{-h} é a média dos valores das origens dado pela Equação 22:

$$m_{-h} = \frac{1}{N(h)} \sum_{i=1}^{N(h)} x_i \quad (22)$$

e m_{+h} é a média dos valores das extremidades dos vetores que pode ser observado na Equação 23:

$$m_{+h} = \frac{1}{N(h)} \sum_{i=1}^{N(h)} y_i \quad (23)$$

σ_{-h} é o desvio padrão dos valores de x_i e σ_{+h} é o desvio padrão dos valores de y_i conforme observado nas Equações 24 e 25 respectivamente:

$$\sigma_{-h} = \left[\frac{1}{N(h)} \sum_{i=1}^{N(h)} x_i^2 - m_{-h}^2 \right]^{\frac{1}{2}} \quad e \quad (24)$$

$$\sigma_{+h} = \left[\frac{1}{N(h)} \sum_{i=1}^{N(h)} y_i^2 - m_{+h}^2 \right]^{\frac{1}{2}} \quad (25)$$

Neste trabalho, os descritores de Haralick e o correlograma foram utilizados para extração das características de textura das regiões de interesse para em seguida serem classificadas em *massa* e *não-massa*.

3.4.13 Máquina de vetores de suporte

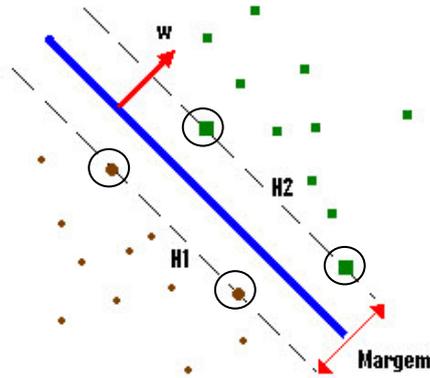
Fundamentada na Teoria da Aprendizagem Estatística, a MVS, foi desenvolvida por Monteiro e Vapnik (1995) com o intuito de resolver problemas de classificação de padrões. Segundo Haykin (1999) a MVS é uma outra categoria das redes neurais alimentadas adiante, ou seja, redes cujas saídas dos neurônios de uma camada alimentam os neurônios da camada posterior, não ocorrendo a realimentação. A ideia principal de uma máquina de vetor de suporte é construir um hiperplano como superfície de decisão de tal forma que a margem de separação entre exemplos positivos e negativos seja máxima.

Uma das grandes vantagens da MVS é seu alto poder de generalização. Isto ocorre, pois a complexidade da hipótese não dependerá do número de atributos, mas, sim, da margem com que eles separam os dados (SPRINGER, 1998). Este fator é muito interessante quando lidamos com problemas de classificação baseados em imagens, pois a dimensão dos seus vetores de atributos é geralmente grande.

3.4.13.1 Hiperplano ótimo

Um hiperplano ótimo separa os dados com a máxima margem possível, que é definida pela soma das distâncias entre os pontos positivos e os pontos negativos mais próximos do hiperplano. Estes pontos são chamados de vetores de suporte e estão circulos na Figura 12.

Figura 12: Hiperplano com vetores de suporte. Onde os quadros verdes e os losangos marrons representam dados de treinamento de diferentes classes; os quadros e losangos envolvidos por círculos são os vetores de suporte; as linhas diagonais tracejadas H1 e H2 são as margens; a linha azul é o hiperplano ótimo e a seta vermelha w é o vetor peso.



O hiperplano é construído com base em treinamento prévio em um conjunto finito de dados (VAPNIK apud MONTEIRO, 2011). Assumindo o conjunto de treinamento $\{x_i, y_i\}$, $y_i \in \{\pm 1\}$, $x_i \in \mathbb{R}^N$ onde x_i é o i -ésimo elemento de entrada e y_i é o seu respectivo valor de classe para x_i , $i = 1, \dots, l$. O cálculo do hiperplano com margem ótima é dado pela minimização de $\|w\|^2$ obedecendo as restrições conforme observado na Equação 26:

$$y_i(x_i \cdot w + b) - 1 \geq 0, \forall_i \quad (26)$$

onde w é a normal ao hiperplano, “ \cdot ” é símbolo do produto escalar e b é o bias. Este é um problema quadrático de otimização, que pode ser transformado para forma dual, onde depende apenas dos multiplicadores de Lagrange a_i conforme observado na Equação 27:

$$u = \sum_{i=1}^N a_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N a_i a_j y_i y_j (x_i \cdot x_j) \quad (27)$$

respeitando as restrições da relação linear observado na Equação 28:

$$\sum_i^N a_i y_i = 0 \quad (28)$$

e as restrições da inequação 29:

$$a_i \geq 0, \forall_i \quad (29)$$

com a solução dada pela Equação 30:

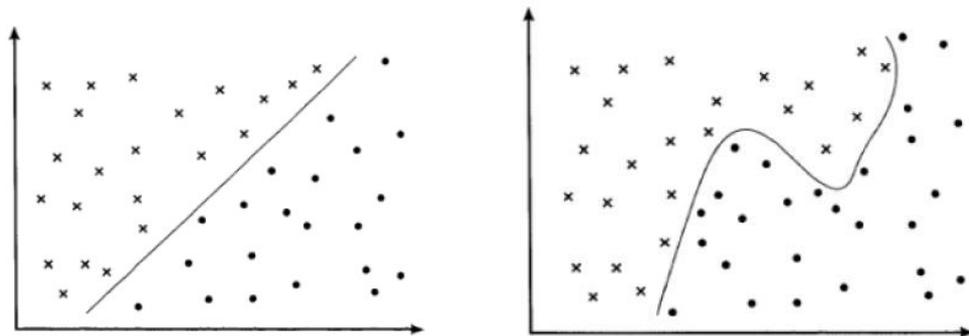
$$w = a_i y_i x_i \quad (30)$$

onde N é o número de exemplos de treinamento. Os elementos mais próximos ao hiperplano são chamados de vetores de suporte e estão localizados nos planos H_1 e H_2 da Figura 12. Estes são os pontos mais importantes, pois são eles que definem a margem de classificação da SVM (BURGES, 1998).

3.4.13.2 MVS para padrões não-linearmente separáveis

Um conjunto de dados é dito ser não-linearmente separável, caso não seja possível separar os dados com um hiperplano. A Figura 13 mostra um conjunto linearmente e outro não-linearmente separável.

Figura 13: Conjunto de dados (a) linearmente separáveis, (b) não-linearmente separáveis.



Fonte: Gonçalves (2009).

Para estender a MVS linear a resolução de problemas não-lineares foram introduzidas funções reais, que mapeiam o conjunto de treinamento em um espaço linearmente separável, o espaço de características. Esse espaço passará a ter uma dimensão bem grande, e, através dele, a amostra poderá ser linearmente separável. Dessa maneira, o hiperplano de separação é definido como uma função linear de vetores retirados do espaço de características ao invés do espaço de entrada original. Essa construção depende do cálculo de uma função K de núcleo de um produto interno (HAYKIN; ENGEL, 2008). A função K pode realizar o mapeamento das amostras para um espaço de dimensão muito elevada sem aumentar a complexidade dos cálculos. A Equação 31 exibe o resultado da Equação 27 com o K .

$$u = \sum_{i=1}^N a_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N a_i a_j y_i y_j K(x_i \cdot x_j) \quad (31)$$

A função Kernel mais comumente utilizada é a função radial de base (RBF) (HAYKIN; ENGEL, 2008) que pode ser observada na Equação 32.

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (32)$$

Neste trabalho a Máquina de Vetores de Suporte foi utilizada para classificar as regiões de interesse em *massa* ou *não-massa*.

3.4.14 Validação de resultados

O reconhecimento de padrão não é um processo perfeito, pois através dele não alcançamos a certeza, mas, sim, a probabilidade de estar certo.

Em problemas ligados a área da saúde, a estrutura básica dos testes de classificação é para determinar quão bem um teste discriminará a presença ou ausência de uma doença (LUNA, 2007).

Quando se avalia um teste de diagnóstico quatro situações serão possíveis:

- 1) Verdadeiro Positivo (VP) – É o caso em que o classificador retorna que o diagnóstico é positivo e o paciente de fato possui a enfermidade.
- 2) Falso Positivo (FP) – É o caso em que o classificador retorna que o diagnóstico é positivo, mas o paciente não possui a enfermidade.
- 3) Falso Negativo (FN) – É o caso em que o classificador retorna que o diagnóstico é negativo, mas o paciente não possui a enfermidade.
- 4) Verdadeiro Negativo (VN) – É o caso em que o classificador retorna que o diagnóstico é negativo e o paciente de fato não possui a enfermidade.

A partir dessas situações podemos calcular:

- a) Sensibilidade (S) - Taxa que classifica como positivos todos os exemplos que são de fato positivos.

$$S = \frac{VP}{VP + FN} \quad (33)$$

- b) Especificidade (E) - Taxa com que classifica como negativos todos os exemplos que são de fato negativos.

$$E = \frac{VN}{VN + FP} \quad (34)$$

- c) Acurácia (A) - Porcentagem das tuplas dos dados de teste que são corretamente classificadas.

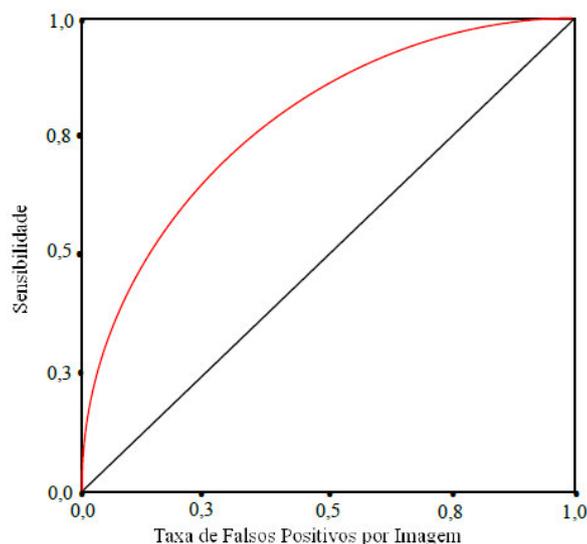
$$A = \frac{VP + VN}{VP + VN + FP + FN} \quad (35)$$

- d) Taxa de Falso Positivos por Imagem (FPI) – Mede-se a média de falsos positivos por imagem.

$$FPI = \frac{\sum_{i=1}^n i_{FP}}{n} \quad (36)$$

- e) Curva FROC – Uma curva FROC (*Free Response Operating Characteristic*) expressa a relação entre a sensibilidade e a taxa de falsos positivos por imagem em um processo de detecção de lesões em exames (CHAKRABORTY; WINTER, 1990). A métrica a ser observada na curva é a área sob a curva FROC (ASCFROC) que quanto mais próximo de 1 significará que menor foi a taxa de falsos positivos por imagem e maior foi a sensibilidade. Na Figura 14, tem-se um exemplo de uma curva FROC.

Figura 14: Exemplo de curva FROC.



Nesse exemplo (Figura 14) de uma curva FROC, os dados do eixo das ordenadas representam a soma dos percentuais das sensibilidades de cada imagem em relação à sensibilidade total. No eixo das abscissas está a soma dos percentuais de falsos positivos por imagem em relação aos falsos positivos totais. A curva vermelha é a curva FROC que deve se

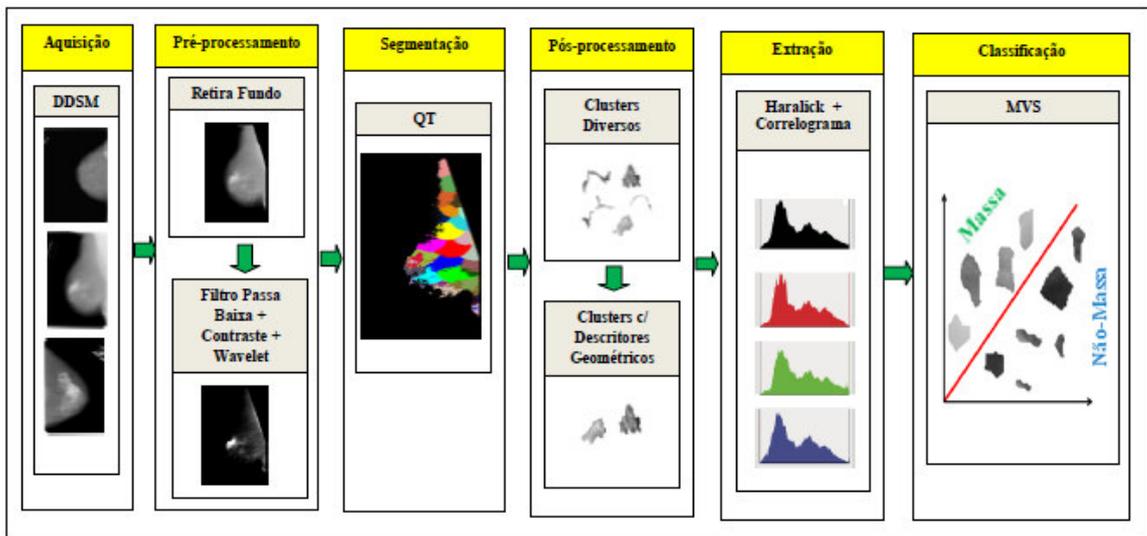
aproximar o máximo possível do canto superior esquerdo distanciando-se da linha diagonal, significando uma maior área sob a curva FROC o que revela uma maior sensibilidade e uma menor taxa de falsos positivos por imagem.

Mesmo existindo varias métricas para constatação do desempenho de um classificador, a métrica mais interessante será a que mantém a performance do mesmo na classificação de novos casos, isto é, um novo teste.

4 METODOLOGIA

Neste capítulo são explicadas as técnicas utilizadas na metodologia deste trabalho para detecção de massas em imagens mamográficas. A metodologia é composta pelas seguintes fases: aquisição das imagens, pré-processamento, segmentação das regiões de interesse, pós-processamento com descritores de forma, extração de características de texturas das ROIs e classificação das regiões de interesse em *massa* e *não-massa*. Esse esquema pode ser observado na Figura 15.

Figura 15: Etapas da metodologia utilizada



A etapa de aquisição é a primeira do processamento de imagens. Nesta pesquisa foi utilizada a base de mamografias digitais DDSM. Na fase seguinte, o pré-processamento tem por objetivo facilitar o processamento das etapas posteriores retirando objetos indesejáveis através do algoritmo de agrupamento K-means com duas classes, o filtro de Canny (1986), a transformada de Hough e o operador morfológico de erosão matemática. Ainda nesta fase realizou-se um melhoramento das imagens com um filtro passa-baixa, um aumento seletivo de contraste e um realce com a WT. Na etapa de segmentação foi aplicada a clusterização com o QT para identificar as regiões suspeitas de conterem massas. Na fase de pós-processamento foram utilizadas as medidas geométricas de excentricidade, circularidade, compacidade e densidade circular para reduzir os candidatos à massa. Na etapa de extração de características foram utilizados os descritores de Haralick e a função correlograma. Por fim, na etapa de classificação foi utilizada a máquina de vetores de suporte para discriminar as regiões suspeitas em *massa* ou *não-massa*.

O restante desse capítulo descreve detalhadamente cada uma das etapas dessa

metodologia.

4.1 Aquisição das imagens

Foram usadas imagens do banco de imagens DDSM, do Hospital Geral de Massachusetts, Universidade Wake Forest e Universidade de Washington na Escola de Medicina de St. Louis.

O DDSM é um banco de dados públicos que contém 2620 casos, que poderão ser adquiridos gratuitamente pela Internet (HEATH, *et al.*, 1998). Nele, as mamas de cada caso são formadas por duas imagens, ou seja: duas projeções uma CC e outra MLO. Este banco de imagens também contém informações extras sobre o exame como a data do estudo, idade do paciente, quantidade de anomalias etc., além de informações sobre a imagem como nome do arquivo, data de digitalização, tipo de filme, tipo do digitalizador, pixels por linha, bits por pixel, marcação do especialista etc.

Neste trabalho foram utilizadas 599 imagens desse banco escolhidas de maneira aleatória, sendo que, dentre elas, 517 imagens deveriam apresentar pelo menos uma massa e as outras 82 restantes deveriam ser normais, isto é, sem massa.

4.2 Pré-processamento

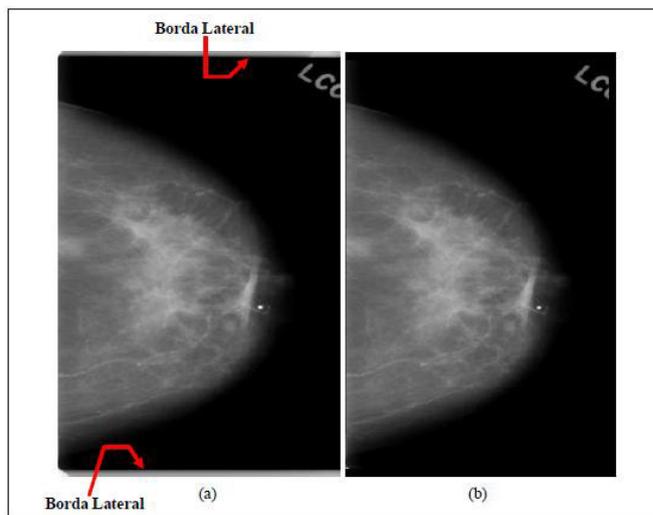
As imagens do banco DDSM apresentam objetos indesejáveis para o processamento da imagem tais como marcas que identificam os pacientes ou o exame, pixels do fundo da imagem e ruídos formados na geração e/ou digitalização da imagem. A interferência de tais objetos poderá influenciar nocivamente os resultados do processamento. Assim sendo, a meta desta fase é a remoção desses elementos prejudiciais à imagem utilizando os métodos de Sampaio (2009) e o melhoramento da distinção visual das estruturas internas da mama.

Primeiramente realizou-se uma redução do tamanho da imagem para 1024 pixels de altura reduzindo-se proporcionalmente a largura com o intuito de tornar o processamento mais rápido.

Logo em seguida foram removidos todos os pontos a 30 pixels de distância das bordas laterais. Isso ocorreu para eliminar da imagem a área entre as bordas do filme da mamografia e os espaços vazios sem o filme conforme observado na Figura 16(SAMPAIO, 2009).

Após as etapas descritas acima, buscou-se isolar a parte que representava a mama da imagem mamográfica completa, retirando as partes que não seriam necessárias para o processamento, deixando somente a mama na imagem. Essas etapas foram feitas, segundo Sampaio (2009), tanto para mamografias CC como para mamografias MLO, conforme veremos a seguir. Também se realizou um melhoramento na imagem para que as massas ficassem mais realçadas e, para isso utilizou-se um filtro passa-baixa, um aumento seletivo de contraste e um realce com a WT que serão vistos adiante.

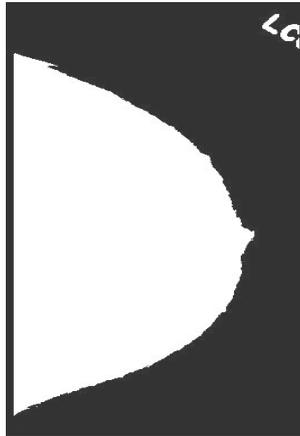
Figura 16: Remoção das bordas laterais: (a) imagem com bordas laterais, (b) imagem com bordas laterais removidas.



4.2.1 Retirada do fundo da mamografia crânio caudal (CC)

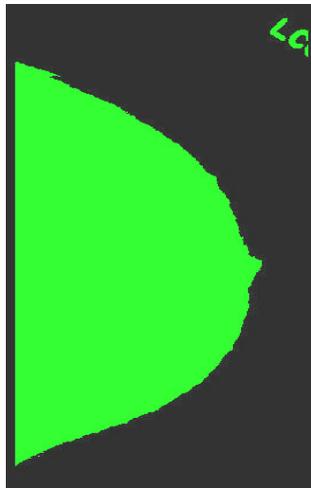
Para isolar a mama da imagem completa utilizou-se a segmentação através da técnica de agrupamento não supervisionada K-means (Seção 3.4.1) que consistiu no particionamento de um conjunto de pixels em dois subconjuntos ($K = 2$) que compartilhavam características semelhantes em relação aos níveis de cinza. Logo, os pixels da mama e das marcas de identificação, que têm os níveis de cinza mais altos, formaram o primeiro grupo e os de níveis de cinza mais baixos como os do fundo da mama formaram o segundo grupo. Em seguida foi feita uma binarização na imagem atribuindo-se o nível de cinza 0 para os pixels do primeiro grupo e 255 para o segundo grupo. Isso poderá ser observado através da Figura 17.

Figura 17: Imagem binarizada com nível de cinza 255 para o grupo que contém a mama e as marcações do especialista; e com nível de cinza 0 para o grupo que contém o fundo da mama.



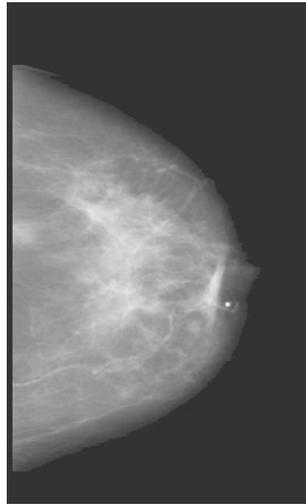
Após essa etapa aplicou-se o algoritmo de crescimento de região (Seção 3.4.2) e para cada região conexa; neste caso, a que contém a mama e as marcações do especialista atribuiu-se a cor verde, sendo, que a que contém o fundo da mama foi desconsiderada. Isso pode ser observado na Figura 18.

Figura 18: Mamografia evidenciando as regiões conexas com a cor verde após a aplicação do algoritmo de crescimento de região.



Logo em seguida verificou-se qual região possuía a maior área sendo esta considerada a mama e os demais considerados objetos que foram eliminados. Então, foram recuperados os níveis de cinza dos pixels da mama e deixou-se todo o restante com o nível de cinza 0. O resultado pode ser observado por meio da Figura 19.

Figura 19: Mamografia com o fundo, marcações dos especialistas e bordas laterais removidas.



4.2.2 Retirada de músculo peitoral da mamografia médio lateral oblíquo (MLO)

O músculo peitoral representa uma região densa predominante em muitas das projeções MLO dos mamogramas. Este pode afetar os resultados dos métodos de processamento de imagens. Métodos baseados em intensidade de níveis de cinza, por exemplo, poderão apresentar baixo desempenho quando aplicados para realizar a diferenciação de estruturas densas, tais como disco glandular, massas suspeitas, visto que o músculo peitoral aparece com aproximadamente a mesma densidade que os tecidos densos de interesse na imagem (Borges e Giuliato, 2008).

Essas imagens receberam um novo pré-processamento para retirada do músculo peitoral. Primeiramente verifica-se o lado em que se encontra o músculo peitoral. Tal localização é feita dividindo-se a imagem na metade de sua largura (Figura 21b), calculando-se então a média da intensidade dos pixels de cada metade. A metade em que se encontra a maior média é a que abrange a maior parte da mama juntamente com o músculo peitoral (Figura 21c). Todos os pixels que estiverem abaixo da metade da altura da imagem, que contém a maior média de nível de cinzas dos pixels são removidos conforme a Figura 21d.

Dando-se sequência ao processo de extração do músculo peitoral foi aplicado o filtro de Canny (Seção 3.4.3) para detecção das bordas conforme observado através da Figura 21e. Em seguida são removidas todas as bordas que não estejam na direção da borda associada ao músculo peitoral (Figura 21f) com o operador morfológico de erosão (Seção 3.4.4) que utiliza dois elementos estruturantes, um para o músculo peitoral da direita (Figura 22a) e outro para o da esquerda (Figura 22b). Sequencialmente foi aplicada a transformada de

Hough (Seção 3.4.5) para detecção da reta que melhor representa a borda do músculo peitoral (Figura 21g). Por fim, todos os pixels que estão da borda do músculo até a reta traçada pela transformada de Hough são removidos restando apenas à mama sem o músculo peitoral conforme observado na Figura 20h.

Figura 20: Fases da retirada do músculo peitoral: (a) Mamografia com o fundo, marcações dos especialistas e bordas laterais removidos, (b) imagem dividida na metade da sua largura, (c) imagem que contém o lado com maior média dos níveis de cinza dos pixels que a compõem, (d) imagem com os pixels abaixo da metade da altura do lado que contém a maior média de nível de cinza dos pixels removidos, (e) bordas detectadas pelo filtro de Canny, (f) bordas com a mesma direção do músculo peitoral resultantes do operador morfológico de erosão, (g) reta resultante da transformada de Hough e (h) imagem sem o músculo peitoral.

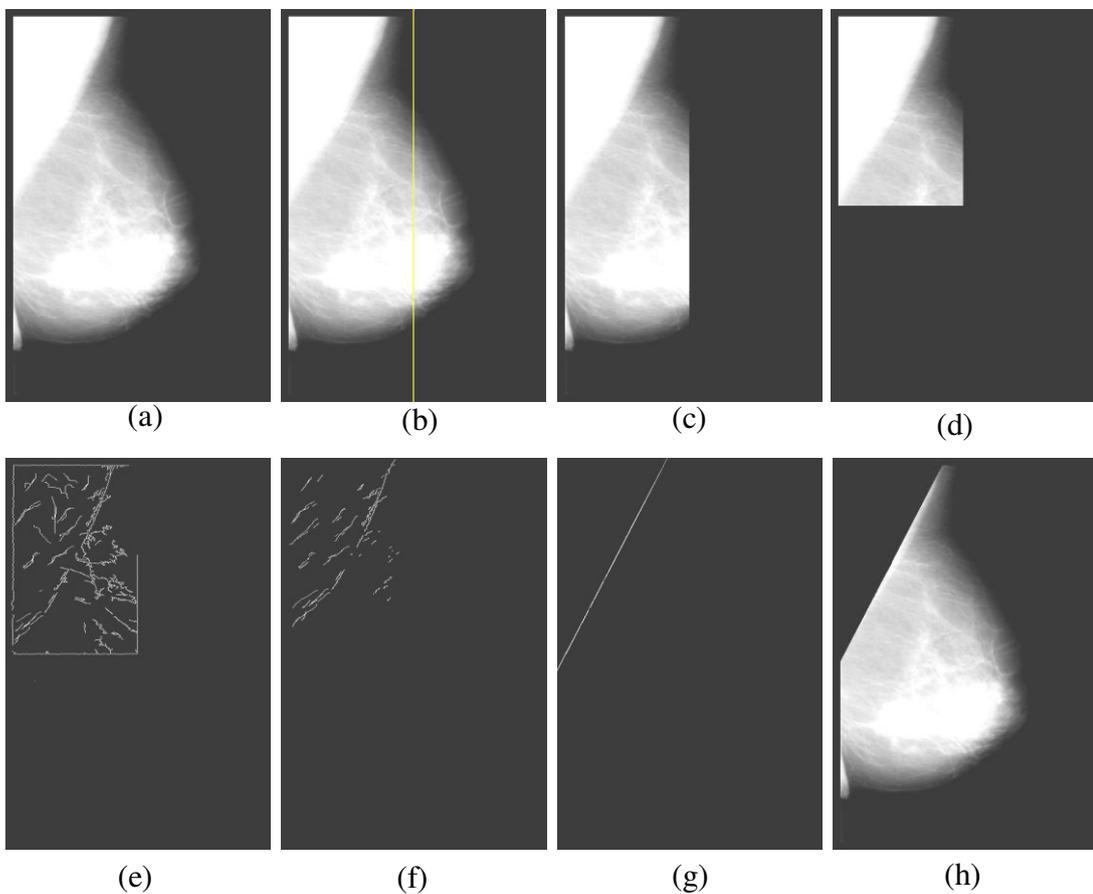
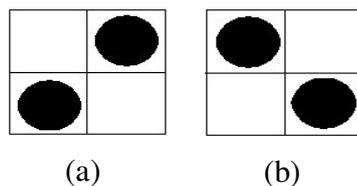


Figura 21: Elementos estruturantes: (a) para o músculo peitoral da esquerda, (b) para o músculo peitoral da direita.



Após as etapas do pré-processamento, deu-se continuidade ao processamento através do tratamento das imagens com o filtro passa-baixa, aumento seletivo da escala de

contraste e realce com a WT com o intuito de realizar-se uma melhor distinção e destaque das estruturas internas das mamas e assim facilitar a fase seguinte que é a clusterização com o QT.

4.2.3 Filtragem com o filtro passa-baixa

Com a utilização do filtro passa-baixa (Seção 3.4.6) buscou-se realizar uma “suavização” na imagem com o intuito de tornar as ROIs das mamas mais homogêneas, minimizando a interferência dos ruídos. Foi observado que esse procedimento melhora a capacidade de clusterização do QT, pois quanto mais uniformes são as estruturas, maior é a precisão da segmentação.

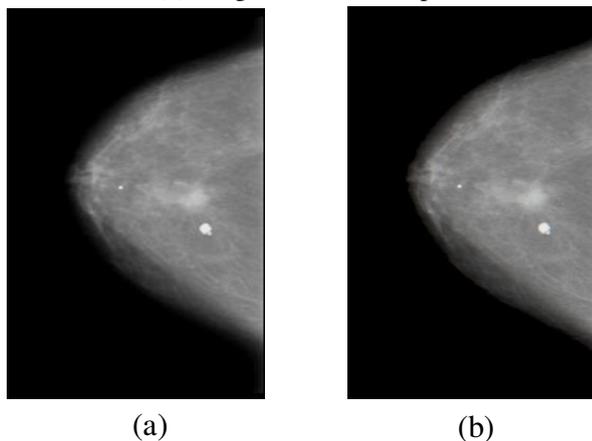
Nesta metodologia foi utilizado o filtro passa-baixa da média com uma máscara 3x3 com seus coeficientes iguais a 1 e um fator de normalização igual a soma dos seus coeficientes, conforme observado na Figura 22.

Figura 22: Máscara do filtro passa-baixa da média.

	1	1	1
1/9	1	1	1
	1	1	1

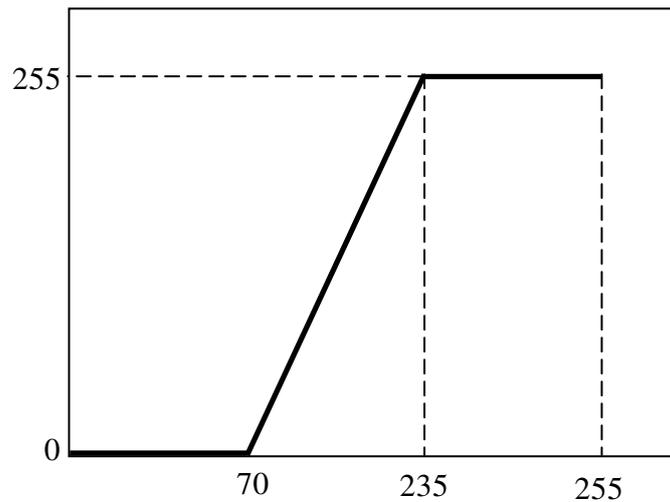
O resultado da aplicação da filtragem é exibido na Figura 23.

Figura 23: Aplicação do filtro passa-baixa: (a) imagem sem o filtro passa-baixa e (b) imagem com o filtro passa-baixa.

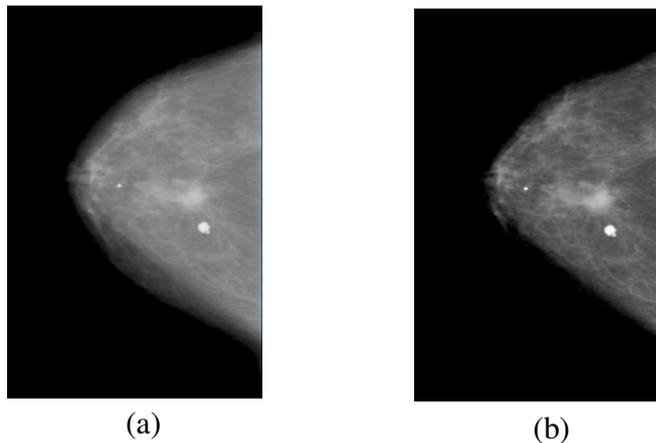


4.2.4 Aumento seletivo de contraste

Nesta etapa buscou-se tornar mais perceptível as ROIs através do aumento seletivo do contraste (Seção 3.4.7). Realizou-se um mapeamento nos níveis de cinza da imagem conforme a Figura 24.

Figura 24: Aumento seletivo do contraste

O valores de 70 e 235 representam os níveis de cinza mínimos e máximos das massas observados empiricamente nos diversos mamogramas deste trabalho. Sendo que os pixels que estavam nesse intervalo foram escalados para os valores de níveis de cinza de 0 a 255. Aos demais pixels foram mapeados para o valor zero. Com isso atribui-se maior evidência às estruturas que poderão vir a ser massas. Na Figura 25, poderemos observar o aumento do contraste aplicado sobre da imagem com filtro passa-baixa da fase anterior.

Figura 25: Aplicação do aumento seletivo de contraste: (a) imagem com o filtro passa-baixa e (b) imagem com aumento seletivo de contraste.

4.2.5 Realce com a transformada de wavelet

Para finalização do pré-processamento das mamografias foi aplicado um realce com a WT (Seção 3.4.8) com o objetivo de evidenciar ainda mais as regiões candidatas a massa. Foi utilizada a WT Daubechies 4 (WTDB4) que possuem quatro coeficientes em seus

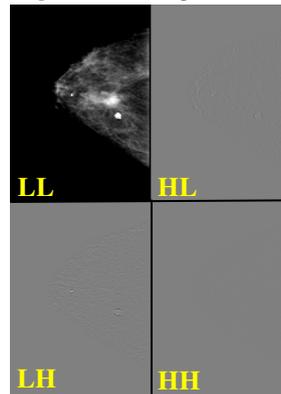
filtros passa-baixa e passa-alta, conforme observado nas Equações 40 e 41.

$$\text{filtro passa alta: } \left(\frac{1-\sqrt{3}}{4\sqrt{2}} - \frac{3-\sqrt{3}}{4\sqrt{2}} \frac{3+\sqrt{3}}{4\sqrt{2}} - \frac{1+\sqrt{3}}{4\sqrt{2}} \right) \quad (40)$$

$$\text{filtro passa baixa: } \left(\frac{1+\sqrt{3}}{4\sqrt{2}} - \frac{3+\sqrt{3}}{4\sqrt{2}} \frac{3-\sqrt{3}}{4\sqrt{2}} - \frac{1-\sqrt{3}}{4\sqrt{2}} \right) \quad (41)$$

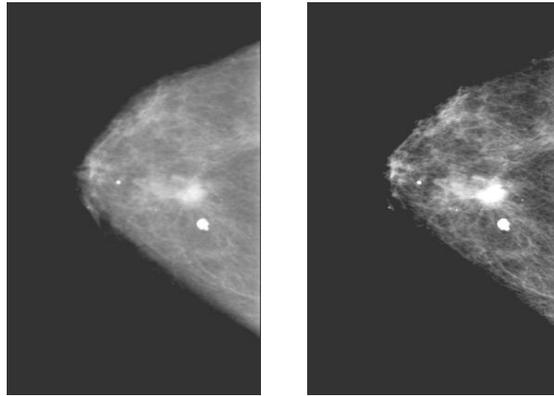
Após a aplicação da WTDB4, com apenas um nível, obteve-se uma imagem de quatro quadrantes (LL, HL, LH e HH) onde cada um representava um grupo de coeficientes. Isso pode ser visualizado com base na Figura 26.

Figura 26: Imagem com quatro grupos de coeficientes



Após a decomposição da imagem em seus grupos de coeficientes foi aplicada em cada coeficiente uma função linear (Equação 9) com o intuito de mapeá-los em outros coeficientes visando o realce da imagem ao efetuar-se a WT inversa. Após alguns testes empíricos o melhor valor para o K da equação linear foi $\sqrt{2}$. O resultado da aplicação do realce com a WT na imagem com aumento seletivo de contraste poderá ser visto através da Figura 27.

Figura 27: Aplicação do realce com a WT: (a) imagem com aumento seletivo de contraste e (b) imagem com realce WT.



4.3 Segmentação

Neste trabalho, foi utilizado o algoritmo de clusterização QT (Seção 3.4.9) para realizar a segmentação das regiões de interesse. Na implementação do QT foram utilizados os diâmetros máximos e mínimos de 100 e 15 pixels respectivamente para cada cluster formado pelo algoritmo. Esses valores de diâmetros foram os que obtiveram os melhores resultados para clusterização das ROIs através da realização de vários testes empíricos. Esse diâmetro mínimo, que não consta no algoritmo QT original, foi colocado nesta metodologia com o objetivo de evitar que clusters com diâmetros muito pequenos fossem formados, pois por meio de observações em várias mamografias constatou-se que diâmetros menores que esse não correspondiam aos diâmetros das massas.

Nesta metodologia, considera-se como critério para um pixel escolhido aleatoriamente pertencer a um cluster candidato que o valor calculado (C) entre ele e o pixel de referência desse cluster, através da Equação 42, seja menor ou igual ao diâmetro de 100 pixels. Só ressaltando que os clusters candidatos formados com diâmetros menores que 15 pixels são dispensados pelos motivos já expostos acima.

$$C = \sqrt{(i - i')^2 + (j - j')^2 + (pixel - pixel')^2} \quad (42)$$

onde i e j são os índices de um pixel de referência do cluster candidato, i' e j' são os índices do pixel escolhido aleatoriamente e $pixel$ e $pixel'$ são os níveis de cinza dos pixels de referência do clusters candidatos e dos pixels escolhidos aleatoriamente, respectivamente. Nas Tabelas 2, 3, 4 e 5, pode ser observado um exemplo com o funcionamento do QT.

Na Tabela 2, tem um conjunto de pixels: A, B, C, D, E e F distribuídos de modo que

todos os pixels possam interagir entre si, através da Equação 42, formando os candidatos a *clusters*. Cada pixel contém os índices de sua posição, em azul, e o seu nível de cinza, em vermelho. O *cluster* que será escolhido dentre os *clusters* candidatos será aquele que contém mais pixels. Os demais pixels que não forem inseridos nesse *cluster* “vencedor” irão participar da formação dos outros *clusters*.

Na Tabela 3, o valor de C resultante da relação de todos os pixels entre si pode ser observado. Já na Tabela 4, elipses estão marcando todos os valores de C que são menores ou iguais a 100 e maiores ou iguais a 15, lembrando que os que possuem o C iguais a 0 estão marcados, mesmo sendo menor que 15, porque se trata do cálculo do C entre um pixel e ele mesmo. As elipses azuis estão destacando a relação do pixel A com todos os demais que satisfazem a condição imposta para o C. Nessa mesma circunstância as elipses amarelas, vermelhas, marron, verde e lilás estão destacando os valores dos C para as relações dos pixels B, C, D, E e F respectivamente. Na última coluna dessa tabela, é observado os candidatos a *clusters* formados com suas respectivas quantidades de pixels, sendo que o cluster escolhido foi aquele que contém quatro pixels, ou seja, o que possui mais pixels e está envolvido por um retângulo amarelo.

Tabela 2: Conjunto dos pixels A, B, C, D e F distribuídos de modo a possibilitar a relação de todos entre si.

	A(170, 180, 45)	B(180, 200, 50)	C(150, 215, 35)	D(10, 15, 255)	E(240, 100,115)	F(250, 200, 110)
A(170, 180, 45)						
B(180, 200, 50)						
C(150, 215, 35)						
D(10, 15, 255)						
E(240, 100, 115)						
F(250, 200, 110)						

Tabela 3: Parametro C resultante da relação de todos os pixels entre si.

	A(170, 180, 45)	B(180, 200, 50)	C(150, 215, 35)	D(10, 15, 255)	E(240, 100,115)	F(250, 200, 110)
A(170, 180, 45)	C = 0	C = 22,9	C = 41,5	C = 311,3	C = 127,3	C = 105
B(180, 200, 50)	C = 22	C = 0	C = 36,7	C = 324,2	C = 133,5	C = 92,2
C(150, 215, 35)	C = 41,5	C = 36,7	C = 0	C = 328,6	C = 166,5	C = 125,9
D(10, 15, 255)	C = 311,3	C = 324,3	C = 328,6	C = 0	C = 282,3	C = 335,9
E(240, 100, 115)	C = 127,3	C = 133,5	C = 166,5	C = 282,3	C = 0	C = 100,6
F(250, 200, 110)	C = 87,1	C = 70,7	C = 104,2	C = 360,3	C = 114,5	C = 0

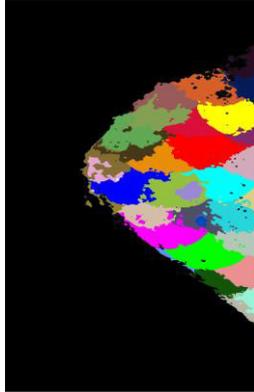
Tabela 4: Elipses marcando os valores de C menores ou iguais a 100 e maiores ou iguais a 15 e com a última coluna indicando os pixels de todos os candidatos a *cluster* e destacando com um retângulo amarelo o *cluster* escolhido, ou seja, o que possui mais pixels.

	A(170, 180, 45)	B(180, 200, 50)	C(150, 215, 35)	D(10, 15, 255)	E(240, 100,115)	F(250, 200, 110)	Candidatos a Clusters
A(170, 180, 45)	C = 0	C = 22,9	C = 41,5	C = 311,3	C = 127,3	C = 105	A, B, C
B(180, 200, 50)	C = 22	C = 0	C = 36,7	C = 324,2	C = 133,5	C = 92,2	A, B, C, F
C(150, 215, 35)	C = 41,5	C = 36,7	C = 0	C = 328,6	C = 166,5	C = 125,9	A, B, C
D(10, 15, 255)	C = 311,3	C = 324,3	C = 328,6	C = 0	C = 282,3	C = 335,9	D
E(240, 100, 115)	C = 127,3	C = 133,5	C = 166,5	C = 282,3	C = 0	C = 100,6	E
F(250, 200, 110)	C = 87,1	C = 70,7	C = 104,2	C = 360,3	C = 114,5	C = 0	A, B, F

Na Figura 28 temos um exemplo de uma mamografia que foi segmentada utilizando-se o algoritmo de clusterização QT, nela cada cluster formado foi pintado com uma

cor diferente.

Figura 28: Mamografia segmentada com o QT com os clusters formados pintados com cores diferentes.

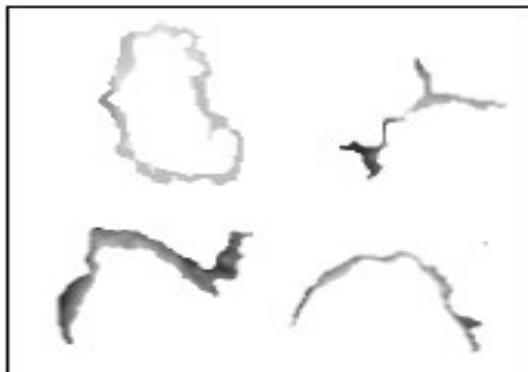


Uma das dificuldades encontrada no processo de segmentação com o QT é a escolha do diâmetro máximo para formação dos clusters, pois só através de vários testes empíricos é escolhido o melhor diâmetro que mais se adequa aos diversos tamanhos das massas encontradas nas imagens com o intuito de detectá-las no processo de segmentação.

4.4 Pós-processamento

Após a etapa de clusterização com QT, foi observado que alguns clusters candidatos à massa apresentavam formas “alongadas”, “retorcidas” ou “ocas”, conforme observado por meio da Figura 29, não condizentes com o formato esperado de uma massa que é mais próximo do “circular” (RANGAYYAN *et al.*, 1997).

Figura 29: Clusters com formatos inadequados



Tais clusters foram eliminados através da análise dos descritores geométricos de

excentricidade (Seção 3.4.10.1), circularidade (Seção 3.4.10.2), compacidade (Seção 3.4.10.3) e densidade circular (3.4.10.4) feitas por um classificador MVS que é treinado a partir de um subconjunto desses clusters, utilizando as medidas geométricas citadas acima. Sendo que, com isso, pode vir a ser reduzida a quantidade de clusters candidatos à massa a passar para as etapas posteriores do processamento.

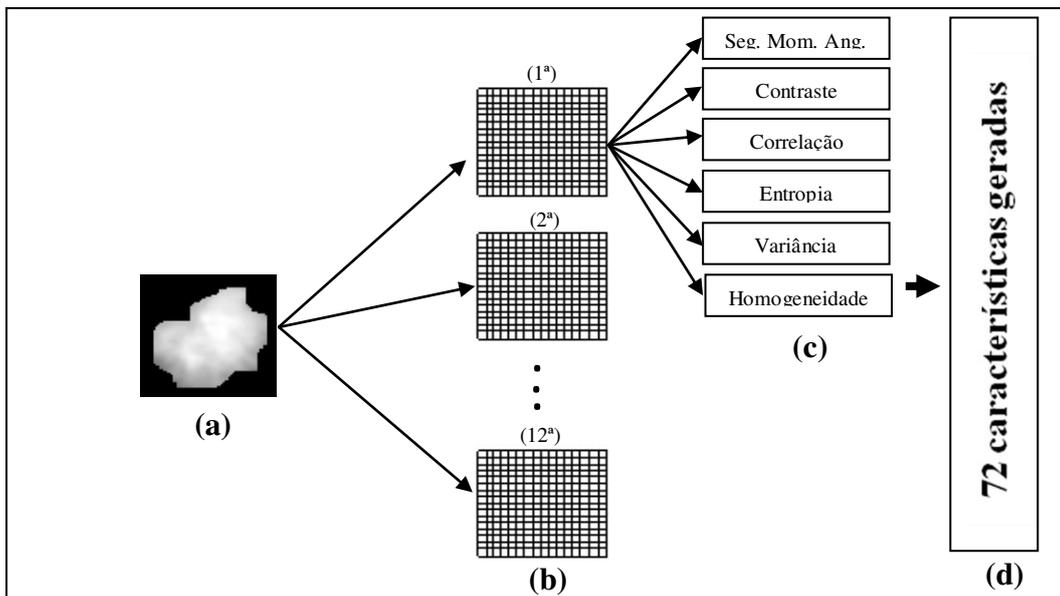
4.5 Extração de características de texturas

Para extração de características de texturas foram utilizados seis descritores de Haralick baseados na matriz de co-ocorrência: segundo momento angular, contraste, correlação, entropia, variância e homogeneidade (Seção 3.4.11.2); e a função correlograma (Seção 3.4.12).

4.5.1 Descritores de Haralick

Primeiramente foram calculadas as matrizes de co-ocorrência (Seção 3.4.11.1) para cada cluster. No cálculo dessas matrizes foi adotada a distância três, ou seja: o pixel de referência se relaciona com três pixels vizinhos subsequentes em uma determinada direção. Essa distância foi adotada, visto que através de alguns testes empíricos com ela, as medidas de textura de Haralick extraídas foram as que melhor caracterizavam os clusters e assim ocasionando uma melhor classificação. As quatro direções adotadas foram de 0° , 45° , 90° e 135° em relação ao plano horizontal. Portanto, para cada combinação da distância com a direção tem-se uma matriz de co-ocorrência; assim obtivemos 12 matrizes de co-ocorrência para cada cluster. Por sua vez, para cada matriz de co-ocorrência foram calculados os seis descritores citados acima chegando-se a um total de 72 características por cluster. Esse esquema pode ser observado na Figura 30.

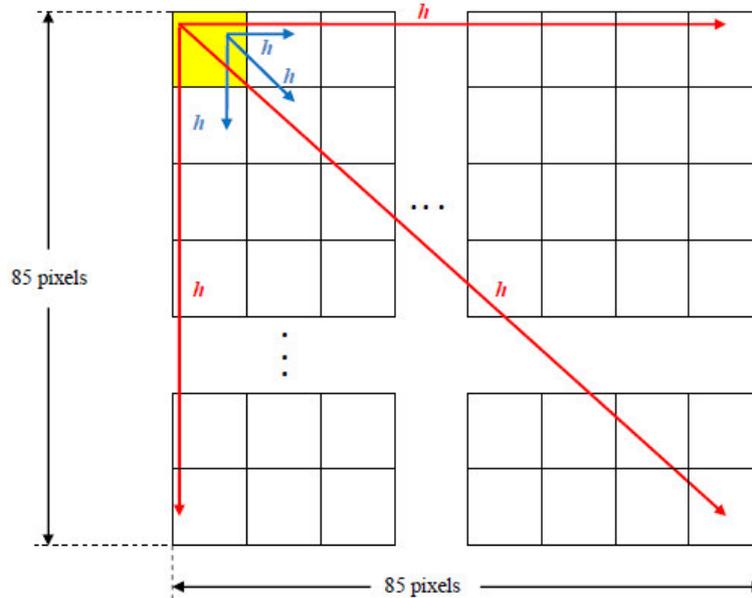
Figura 30: Obtenção dos descritores de Haralick (a) cluster gerado pelo QT, (b) doze matrizes de co-ocorrência geradas do cluster, (c) seis descritores de Haralick extraído de cada matriz de co-ocorrência e (d) um total de 72 características geradas.



4.5.2 Função correlograma

Juntamente com os descritores de Haralick, a função correlograma foi utilizada na extração de características dos clusters. Como os diâmetros dos clusters eram de até 100 pixels foram atribuídos para esta função valores de h (distância do pixel de origem ao pixel da extremidade) que iam de 1 até 85 pixels, sendo que através de testes foi verificado que com a distância h tendo esses valores foram obtidos os melhores resultados. Isso ocorreu porque cada pixel passou a interagir com todos os pixels vizinhos nas direções horizontal, vertical e diagonal distantes até 85 pixels. Assim com essa configuração da função passou-se a obter medidas de textura que especificam bem os clusters, pois são resultantes da relação de, praticamente, todos os pixels das regiões segmentadas entre si, ou seja, são bem robustas. Logo, como cada cluster gerado pelo QT tem até 100 pixels de diâmetro. Esse intervalo de distâncias para o h mostrou-se bastante eficiente na extração das características de textura dos clusters com a função correlograma. Por exemplo, se tivermos um cluster quadrado com 85 pixels de lado e considerando-se o h variando de 1 a 85 pixels e um pixel origem tendo como vizinhos pixels extremidades nas direções horizontal, vertical e diagonal conforme a Figura 31, ter-se-a a seguinte quantidade de características para aquele cluster: 85 (o h variando de 1 a 85) vezes 3 (quantidade de direções dos pixels vizinhos dos pixels origens) que é igual a 255 características.

Figura 31: Cluster quadrado com 85 pixels de lado e com o pixel de origem tendo pixels extremidades nas direções horizontal, vertical e diagonal e com o h variando de 1 a 85 nas três direções.



4.6 Classificação

Nessa etapa foi utilizada a MVS (Seção 3.4.12) com a função Kernel Base Radial para realizar a classificação dos clusters em *massa* ou *não-massa*. Essa fase está dividida em dois momentos: treinamento com validação do modelo MVS gerado e o teste. No primeiro momento os clusters foram divididos com a configuração observada na Tabela 5.

Tabela 5: Configuração dos clusters para treinamento e validação do modelo MVS

	Treinamento (%)	Validação do Modelo MVS (%)
Clusters	70	30
	50	50
	30	70

É importante lembrar que se, por exemplo, forem colocados 70% dos clusters para treinamento e 30% para validação do modelo MVS, serão inferidos que dentro daqueles 70% para treinamento tem 70% de clusters de massas em relação aos 30% que estão na validação do modelo MVS. Isso também vale para os clusters de não-massas e para as demais

configurações. Outro ponto importante é que cada uma dessas três configurações foi executada cinco vezes aleatoriamente, gerando-se um total de quinze modelos MVS.

No segundo momento, a saber, na fase de teste, foram utilizados exames que não fizeram parte da etapa anterior e buscou-se classifica-los com o melhor dos quinze modelos gerados anteriormente.

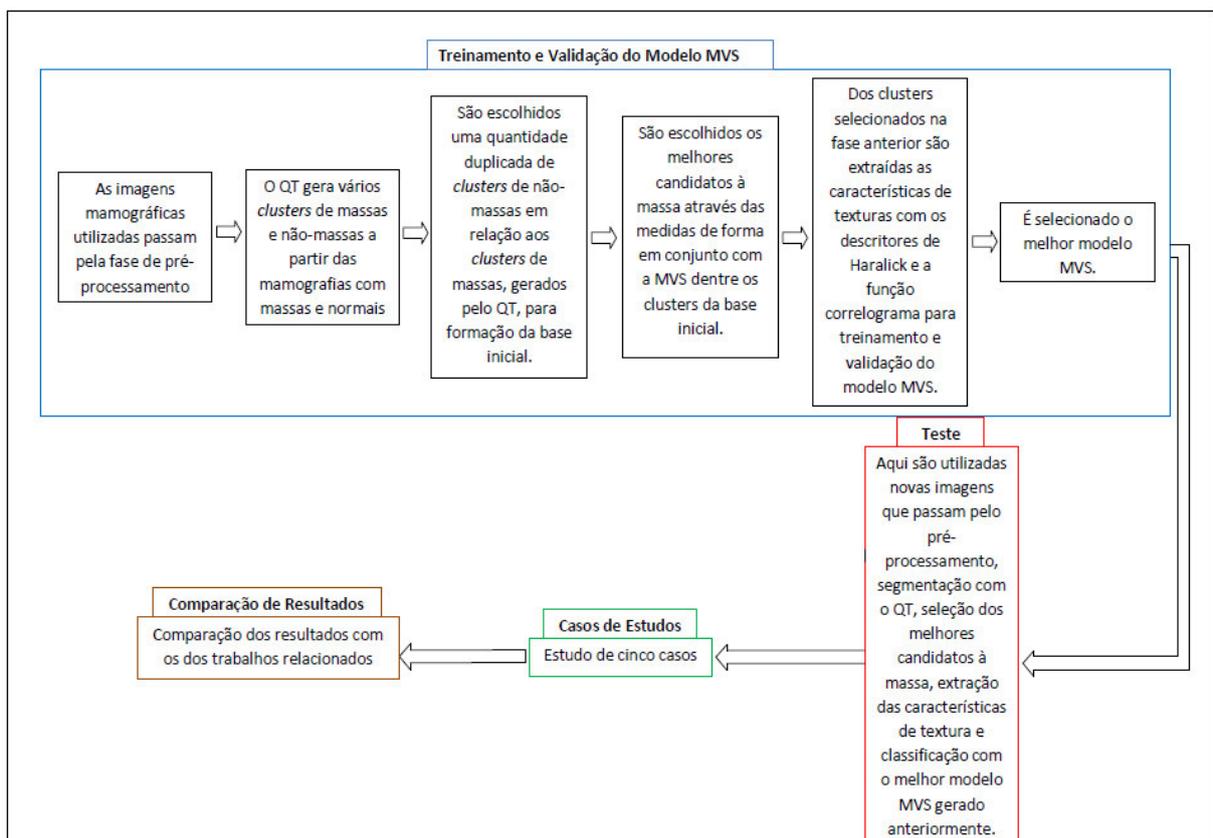
5 RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados os resultados alcançados com a metodologia desenvolvida. São analisadas a atuação das etapas contidas na metodologia apresentada no Capítulo 4. Para isso os resultados alcançados são verificados em dois momentos distintos: O primeiro momento refere-se ao treinamento e validação do modelo MVS, e o segundo momento diz respeito ao teste do processo de detecção das massas. Nesse teste, novas mamografias são utilizadas e são verificadas a sensibilidade, a especificidade e a acurácia, além da quantidade de falsos positivos por imagem e a curva FROC. Também há um estudo de cinco casos de detecção de massas e uma comparação de resultados com os trabalhos relacionados no Capítulo 2.

Nesta metodologia, foram utilizadas 599 imagens sendo que dentre elas 517 apresentavam pelo menos uma massa e 82 eram normais (sem massas). Dessas imagens 497 (com 456 imagens com massa e 41 normais) foram utilizadas para o treinamento e validação do modelo MVS e 100 (59 com massas e 41 normais) foram utilizadas para verificação do processo de detecção de massas nas imagens.

Na Figura 32 pode ser observado um esquema geral com o fluxo de análise dos resultados.

Figura 32: Fluxo de análise dos resultados



5.1 Treinamento e validação do modelo MVS

No treinamento e validação do modelo MVS foram utilizadas 497 imagens de mamografias digitais, sendo que dentre elas 456 eram mamografias contendo pelo menos uma massa e 41 eram normais. Essas mamografias foram pré-processadas (Seção 4.2) e segmentadas com o QT (Seção 4.3) resultando em vários *clusters* do tipo *massa* e *não-massa*.

Em 31 imagens, das 456 imagens que continham massas usadas para treinamento e validação do modelo MVS, o processo de segmentação falhou em incluir as massas no conjunto de regiões de interesse, o que equivale a 6,12% dos *clusters*. Assim sendo, somente os *clusters* das 425 imagens mamográficas restantes serviram de base para o treinamento e formação do modelo MVS. Esta situação indica que os parâmetros utilizados no QT devem ser melhor otimizados para o processo de segmentação das imagens.

Para o treinamento da MVS a amostra foi definida na proporção de 1 *massa* para cada 2 *não-massas*. Essa proporção se deu porque a quantidade de *clusters* de *massas* em relação aos de *não-massas*, gerados pela segmentação com o QT em cada imagem mamográfica, era bastante inferior. Assim para a MVS a quantidade de *clusters* de *não-massas* em relação aos de *massas* deveria ser maior nessa fase de treinamento e geração do modelo MVS, para poder estar conforme a realidade quantitativa de *clusters* de *massa* em relação aos de *não-massas* encontrados durante a fase de teste. Essa proporção em si de 1 *massa* para cada 2 *não-massas*, utilizada no treinamento e geração do modelo MVS, foi alcançada empiricamente através de testes. Desta forma, de todos os *clusters*, achados nas 425 mamografias, foram escolhidos aleatoriamente 1396 *clusters* de *massa* e 2522 *clusters* de *não-massa*, totalizando 3918 *clusters*.

Desses 3918 *clusters*, foram escolhidos alguns que melhor representem as *massas*, ou seja, que sejam mais “circulares”, e alguns que melhor representem as *não-massas*, ou seja, aqueles mais “retorcidos” e “alongados” conforme Rangaraj *et al.* (1997). Desses *clusters* escolhidos, foram extraídas as medidas geométricas e com essas, foi treinada a MVS e gerado o modelo MVS para selecionar quais dos 3918 *clusters* tinham o formato condizente com as massas para passar para a fase de extração de características de texturas. Esses passos são mostrados nas próximas seções.

5.1.1 Seleção dos melhores candidatos à massa

O objetivo desta etapa é selecionar os melhores candidatos à massa de acordo com as suas características geométricas através da MVS, ou seja, filtrar os *clusters* com formato

mais circular e descartar os que apresentam características indesejáveis (alongados ou retorcidos demais). Sendo que assim, somente os *clusters* selecionados nesta fase passarão para a etapa de extração de características de textura.

Dos 3918 *clusters* iniciais, foram escolhidos os que melhor representem as classes de *massas* e *não-massas* de acordo com seus formatos, conforme mencionado acima, para treinamento e validação do modelo MVS com descritores de forma para selecionar os melhores candidatos a massa. Vale destacar que a classe considerada como não-massa usada para o treinamento e validação do modelo MVS com medidas de forma é composta por *clusters* bem retorcidos e alongados e que, dentre eles, podem estar tanto *clusters* de *massas* quanto de *não-massas* (de acordo com o especialista), mas que, se apresentarem tais formatos, serão considerados como não-massas para treinamento do classificador com intuito dele “aprender” sobre tais objetos, “reconhecê-los” no teste, que será feito na base de 3918 *clusters*, para em seguida serem eliminados e não seguirem para fase posterior de extração das características de texturas.

Com isso, foram escolhidos 1167 dos 3918 *clusters* que melhor representassem as *massas* e *não-massas*. Dentre esses 1167 *clusters*, 475 representam as *massas* (*clusters* bem circulares) e 692 representam as *não-massas* (*clusters* alongados e retorcidos). Dos 475 que representavam as *massas*, 380 (80%) foram colocadas para treinamento da MVS e 95 (20%) para validação do modelo MVS. Dos 692 *clusters* que representavam as *não-massas*, 554 (80%) foram utilizados para treinamento da MVS e 138 *clusters* (20%) foram utilizados para validação do modelo MVS.

Essa configuração para treinamento e validação do modelo MVS com descritores geométricos pode ser observada na Tabela 6.

Tabela 6: Configuração dos *clusters* de *massas* e *não-massas* de acordo com as medidas geométricas para treinamento e validação do modelo MVS.

Etapas	<i>Clusters</i> de <i>massas</i>	<i>Clusters</i> de <i>não-massas</i>
Treinamento da MVS	380 (80%)	554 (80%)
Validação do modelo MVS	95 (20%)	138 (20%)

Com essa configuração, a validação do modelo MVS gerado alcançou os resultados que podem ser observados na Tabela 7.

Tabela 7: Resultados alcançados para a validação do modelo MVS gerado de acordo com os descritores de forma.

VP	FP	VN	FN	Sensibilidade (%)	Especificidade (%)	Acurácia (%)
81	19	116	17	82,65	85,92	84,54

Com esse modelo gerado e validado de acordo com os resultados da Tabela 4, os 3919 *clusters* da base inicial foram classificados em *clusters* de *massas* e *não-massas* de acordo com suas formas. Logo, desses 3919 *clusters* apenas 2033 (704 *clusters* de *massas* e 1329 *clusters* de *não-massas*) foram selecionados como melhores candidatos à massa, sendo passando então para a etapa seguinte.

Na próxima etapa, esses *clusters* resultantes passarão por um processo de extração das características de textura através dos descritores de Haralick e da função correlograma, sendo que através dessas características realizar-se-á um outro treinamento do classificador seguido da validação do modelo MVS, através do qual será realizado um teste final com novas mamografias.

5.1.2 Treinamento e validação do modelo MVS com medidas de textura

Os *clusters* resultantes da etapa anterior têm suas características de textura extraída para fazerem parte do treinamento e validação dos modelos MVS gerados. A nova base consta de 2033 *clusters* resultantes do pós-processamento, citado acima, que seleciona os melhores candidatos à massa, com descritores geométricos, para esta fase. Essa base é composta 704 *clusters* de *massas* e 1329 *clusters* de *não-massas*.

O treinamento e a validação dos modelos MVS foram configurados do seguinte modo: Dos 2033 *clusters* resultantes do pós-processamento, 610 foram utilizados para treino do classificador e 1423 para validação do modelo MVS o que equivale a 30% dos *clusters* para treino e 70% para a validação do modelo. Dentre os 610 *clusters* utilizados para treino 211 eram *clusters* de *massas* e 399 eram *clusters* de *não-massas*. Dos 1423 *clusters* utilizados para a validação do modelo 493 eram *clusters* de *massas* e 930 eram *clusters* de *não-massas*. Essa configuração, mantendo essa mesma proporção de distribuição dos *clusters* de *massas* e *não-massas* entre treino e validação do modelo, foi classificada cinco vezes de maneira aleatória realizando cinco treinamentos e gerando e validando cinco modelos MVS. Isso se deu para que todos os *clusters* nessa configuração tivessem mais oportunidade de fazer parte tanto do treino quanto da validação do modelo, sendo que assim é verificada a robustez e a generalização da base, e também porque através de cinco classificações com distribuições

aleatórias dos *clusters* entre treino e validação do modelo, mantendo a proporção citada acima, se tem mais possibilidade de alcançar um melhor modelo para ser usado no teste final. A distribuição desses *clusters* podem ser observados na Tabela 8.

Tabela 8: Distribuição dos *clusters* com 30% para o treinamento do classificador e 70% para validação do modelo MVS.

Etapas	Qtd. de Clusters	Clusters de massas	Clusters de não-massas
Treinamento da MVS	610 (30%)	211 (30%)	399 (30%)
Validação do modelo MVS	1423 (70%)	493 (70%)	930 (70%)
Total	2033	704	1329

A segunda configuração dos *clusters* entre o treinamento do classificador e validação do modelo MVS ficou da seguinte maneira: dos 2033 *clusters* resultantes do pós-processamento, 1016 *clusters* foram utilizados para treino e 1017 *clusters* foram utilizados para validação do modelo, o que equivale a aproximadamente 50% dos *clusters* para treinamento e 50% para validação do modelo. Dentre os 1016 *clusters* utilizados para treinamento, 352 são *clusters* de *massas* e 664 são *clusters* de *não-massas*. Dentre os 1017 *clusters* utilizados para validação do modelo 352 eram *clusters* de *massas* e 665 eram *clusters* de *não-massas*. Também para esta configuração dos *clusters* foram realizadas cinco classificações gerando e validando cinco modelos de MVS pelos mesmos motivos abordados acima.

A distribuição dos *clusters*, nessa configuração, pode ser observada na Tabela 9.

Tabela 9: Distribuição dos *clusters* com 50% para o treinamento do classificador e 50% para validação do modelo MVS.

Etapas	Qtd. de Clusters	Clusters de massas	Clusters de não-massas
Treinamento da MVS	1016 (50%)	352 (50%)	664 (50%)
Validação do modelo MVS	1017 (50%)	352 (50%)	665 (50%)
Total	2033	704	1329

Por fim, na última configuração, novamente dos 2033 *clusters* resultantes do pós-processamento, foram utilizados 1423 *clusters* para treino da MVS e 610 *clusters* para validar o modelo. Essas quantidades equivalem a 70% dos *clusters* para treinamento e 30% para validação. No treinamento, dos 1423 *clusters* utilizados, têm-se 493 *clusters* de *massas* e 930 *clusters* de *não-massas*, e na validação do modelo, dos 610 *clusters* empregados, têm-se 211 *clusters* de *massas* e 399 *clusters* de *não-massas*. Novamente foram realizadas cinco classificações de acordo conforme exposto acima.

A divisão dos *clusters* para o treinamento do classificador e validação do modelo MVS pode ser vista na Tabela 10.

Tabela 10: Distribuição dos clusters com 70% para o treinamento do classificador e 30% para validação do modelo MVS.

Etapas	Qtd. de Clusters	Clusters de massas	Clusters de não-massas
Treinamento da MVS	1423 (70%)	493 (70%)	930 (70%)
Validação do modelo MVS	610 (30%)	211 (30%)	399 (30%)
Total	2033	704	1329

Os resultados obtidos com essas configurações para treinamento e validação do modelo MVS podem ser observados na Tabela 11.

Tabela 11: Resultados alcançados com as configurações para o treinamento e validação do modelo MVS com as medidas de textura.

DESCRITORES	Treino /Validação	VP	FP	VN	FN	S(%)	E(%)	A(%)
Correlograma-Haralick	30/70	342	132	786	163	67,72	85,62	79,27
Correlograma-Haralick		346	135	800	142	71	85,56	80,53
Correlograma-Haralick		339	114	808	162	67,66	87,64	80,6
Correlograma-Haralick		357	144	791	131	73,16	84,6	80,67
Correlograma-Haralick		353	152	781	137	72,04	83,71	80
Média							70,316	85,426
Correlograma-Haralick	50/50	258	127	556	75	77,78	81	80,12
Correlograma-Haralick		255	99	559	103	71,23	84,95	80,12
Correlograma-Haralick		233	93	582	108	68,33	86,22	80,22
Correlograma-Haralick		244	86	590	96	71,76	87,28	82,08
Correlograma-Haralick		248	108	554	106	70,06	83,69	79
Média							71,832	84,628
Correlograma-Haralick	70/30	154	58	332	65	70,32	85,13	80,8
Correlograma-Haralick		167	84	314	44	79,15	78,89	79,14
Correlograma-Haralick		155	54	344	56	73,46	86,43	82,26
Correlograma-Haralick		139	46	351	73	65,57	88,41	80,46
Correlograma-Haralick		142	55	362	50	73,96	86,81	82,76
Média							72,492	85,134

Os resultados alcançados nessa etapa nos permite concluir que a classificação com a MVS utilizando os descritores de Haralick em conjunto com a função correlograma apresenta um desempenho considerável, o que pode ser observado na capacidade de

generalização demonstrada na validação dos modelos MVS (Tabela 8). Para as três configurações adotadas, de distribuição dos clusters entre o treinamento do classificador e validação do modelo MVS, que tiveram cinco classificações aleatórias cada, foram alcançados quinze modelos MVS, cada um tendo sua respectiva sensibilidade, especificidade e acurácia. Para a escolha do modelo MVS que iria ser utilizado no teste final desta metodologia foi adotada a seguinte estratégia: primeiramente foi calculada a média das sensibilidades, especificidades e acurácias de cada uma das três configurações que continham cinco classificações aleatórias cada; depois foi verificado quais dessas configurações apresentavam as maiores médias, e conforme observado na Tabela 8 a configuração que tinha 70% dos *clusters* para treino e 30% para validação do modelo MVS (70/30) apresentou as maiores médias de sensibilidade, especificidade e acurácia, iguais a 72,492%, 85,134% e 81,084% respectivamente. Então foi verificado nessa configuração quais das suas cinco classificações apresentavam os maiores valores para sensibilidade, especificidade e acurácia, e conforme observado na Tabela 8 a melhor classificação foi a que apresentou a sensibilidade de 73,96%, a especificidade de 86,81% e a acurácia de 82,76%, sendo que estas estão destacadas com uma linha amarela na Tabela 8.

Logo a partir desses resultados, é possível deduzir que os descritores de Haralick e a função correlograma utilizados nesta metodologia constituem uma ferramenta relevante para extração de características de regiões segmentadas.

A comparação dos resultados dessa metodologia com os dos trabalhos relacionados será feita na Seção 5.4.

5.2 Teste

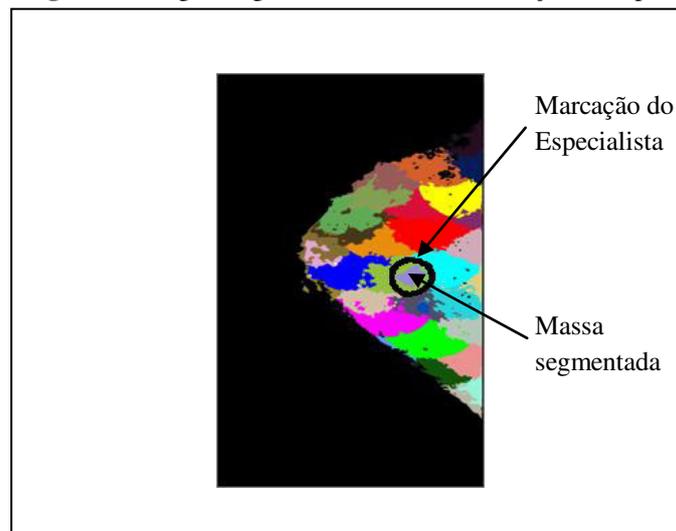
Nesta seção será verificada a eficiência da metodologia proposta de modo geral. E para isso foram usadas 100 novas imagens mamográficas, em que 59 delas contém pelo menos uma massa e 41 são exames normais (sem massas). Logo para cada imagem testada foram seguidas as etapas da metodologia descritas no Capítulo 4. Onde primeiramente o fundo da mamografia contendo objetos indesejáveis, para o processamento, foram removidos através do algoritmo K-means, do filtro de Canny, da transformada de Hough e de um operador morfológico de erosão. Logo em seguida houve um melhoramento das imagens com um filtro passa-baixa, aumento seletivo de contraste e um realce com a WT. Na segmentação, foi realizada uma clusterização com o QT, para seleção dos melhores candidatos a massa (pós-processamento) houve a utilização de medidas geométricas

conjuntamente com o MVS, para extração de características de textura foram utilizados os descritores de Haralick e a função correlograma e para a classificação final foi novamente utilizada a MVS.

5.2.1 Segmentação com o QT dos exames

A análise da eficiência do processo de segmentação (clusterização) com o QT consiste em verificar se o mesmo conseguiu separar ou não as regiões suspeitas de serem massas do restante da imagem mamográfica. Tal verificação na base de imagens DDSM utilizada nesta metodologia é possível à medida que a mesma disponibiliza a marcação do especialista que envolve as lesões contidas nas imagens. Logo, todas as imagens, que ao serem segmentadas apresentassem *clusters* inseridos no contorno do especialista demarcando a lesão, eram contabilizadas como um acerto de segmentação do QT. Tal situação pode ser observada na Figura 33.

Figura 33: Região segmentada dentro da marcação do especialista.



O processo de clusterização com o QT conseguiu segmentar massas em 54 dos 59 exames com massas utilizados para o teste neste trabalho, o que significa um percentual de acerto de 91,52% na segmentação das massas. Também gerou uma quantidade de 192 *clusters* de *massas* e 1214 *clusters* de *não-massas*. Só lembrando que essa quantidade de massas geradas em apenas 59 exames contendo as mesmas se deu por dois motivos: primeiro porque em alguns exames têm-se mais de uma massa por imagem. Em segundo lugar, porque eventualmente o QT pode particionar uma mesma massa em duas ou mais regiões por causa da não similaridade dos pixels que a compõem e/ou por causa diâmetro adotado para a

formação dos *clusters*. Sendo que isso normalmente resulta em uma mesma massa segmentada em regiões com formatos “circulares”, “contorcidos” ou “alongados”, sendo que as que possuem formatos semelhantes a esses dois últimos são eliminadas no pós-processamento com a seleção dos melhores candidatos a massa.

Os resultados alcançados com essa metodologia no teste final utilizando o melhor modelo MVS gerado na etapa de treinamento (Seção 5.2) podem ser observados na Tabela 12.

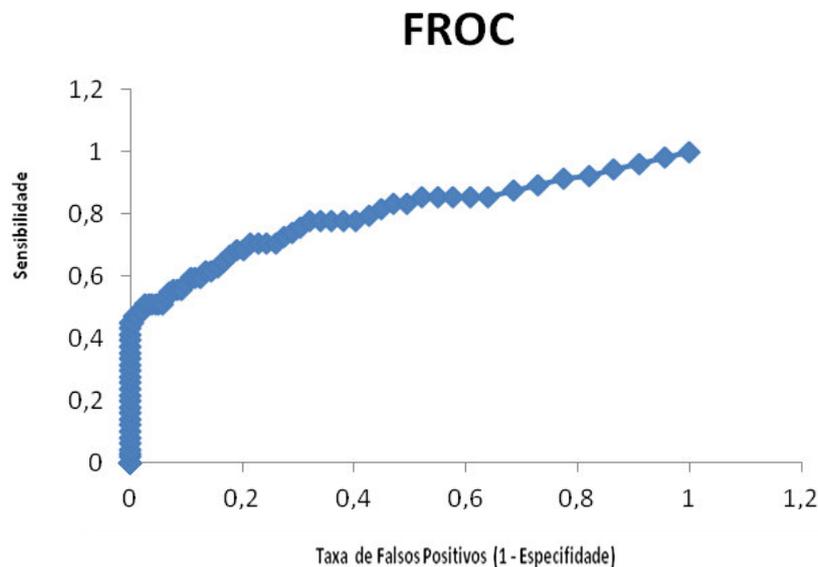
Tabela 12: Resultados alcançados com o teste

TESTE	Clusters de massas	Clusters de não-massas	VP	FP	VN	FN	S (%)	E (%)	A (%)	FPI
	91	601	84	107	494	7	92,31	82,2	83,53	1,12

5.2.2 Análise da curva FROC dos resultados do teste

Ainda relacionado ao teste foi calculada a curva FROC (Seção 3.4.14) que relaciona a taxa de FPI com a sensibilidade. Na Figura 34, pode ser observada a curva FROC gerada com os resultados obtidos no teste, sendo que a área sob a curva froc alcançada foi de 0,8033.

Figura 34: Curva FROC.



O valor da área sob a curva FROC de 0,8033 alcançado é relevante uma vez que está bem próximo de 1 que é o valor de uma área sob uma curva FROC ideal.

Nesses resultados alcançados vale resaltar que faziam parte da base de teste 41 exames normais e 54 exames com massas (lembrando que eram 59 exames com massas, só que em 5 desses o QT falhou na segmentação) logo, o número de *clusters* de *não-massas* é

bastante elevado em relação aos *clusters* de *massa*, sendo que, mesmo após a seleção dos melhores candidatos a massa, essa proporção se manteve em 1 *cluster* de *massa* para cada 7 *clusters* de *não-massas*. Com isso a quantidade de FPI tende a ter certa elevação o que compromete um pouco o valor da especificidade. Mas levando em conta essa considerável quantidade de exames normais nos testes a quantidade de FPI e a especificidade podem ser considerados aceitáveis.

Os resultados obtidos com essa metodologia serão comparados com os dos trabalhos relacionados na Seção 5.4.

5.3 Estudos de casos

Nesta etapa são verificados todos os passos da metodologia trabalhada em testes reais, com o intuito de esmiuçar cada fase e simultaneamente facilitar o entendimento das técnicas utilizadas neste trabalho. Para isso são examinados cinco casos. Na primeira situação tem-se um caso em que a metodologia obteve sucesso na detecção da massa. No segundo caso, a metodologia detectou a massa e outras regiões que não são massas (de acordo com o especialista), mas que o sistema disse que era. No terceiro caso a metodologia não foi capaz de detectar nenhuma massa na imagem. No quarto caso é analisada uma mamografia *normal*, e nessa a metodologia também obteve sucesso ao não identificar massa(s) presente(s) na imagem. Por fim, no quinto caso, em que também foi tratada uma mamografia *normal*, a metodologia falhou ao detectar uma massa na mesma, que segundo o especialista não estava lá.

No segundo, terceiro e quinto casos, são analisadas as possíveis causas que levaram a falha na detecção das massas.

5.3.1 Primeiro caso

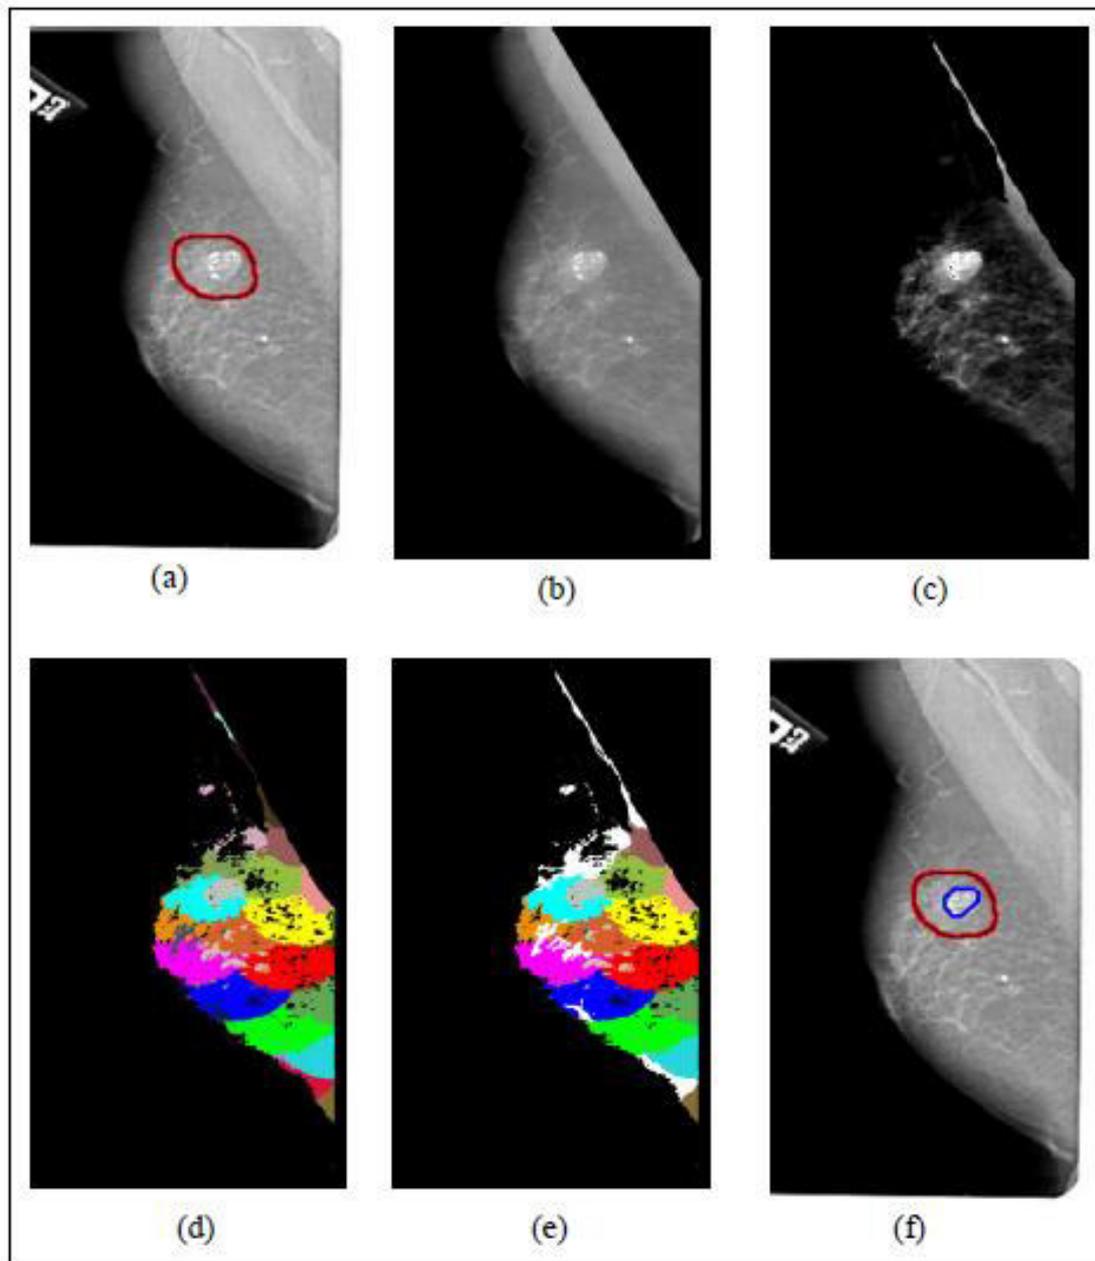
Os passos utilizados para detecção das massas nas mamografias podem ser observados na Figura 35. A imagem mamográfica utilizada neste caso de estudo foi a A_1306_1.LEFT_MLO, do volume benigno 02, da base DDSM, que pode ser observada na Figura 35a, onde a lesão está demarcada com um contorno vermelho do especialista.

No primeiro passo do pré-processamento da imagem são retirados os objetos indesejáveis para o processamento da imagem que não fazem parte da mama em si, como as bordas laterais, músculo peitoral, e rótulos do especialista. Esse procedimento é feito com a

utilização do algoritmo K-means (Seção 3.4.1), do filtro de Canny (Seção 3.4.3), de um operador morfológico de erosão matemática (Seção 3.4.4) e da transformada de Hough (3.4.5) sendo que o resultado pode ser observado na Figura 35b. No segundo momento, ainda no pré-processamento, a imagem passa por um melhoramento de suas estruturas internas através da ação conjunta de um filtro passa-baixa (Seção 3.4.6), um aumento seletivo do contraste (Seção 3.4.7) e um realce com a WT (Seção 3.4.8), cujo resultado é observado na Figura 35c. Na próxima etapa a imagem foi segmentada (Figura 35d) através do algoritmo de clusterização QT (Seção 3.4.9) utilizando os diâmetros máximos e mínimos iguais a 100 e 15 pixels respectivamente.

Observando a imagem resultante da segmentação com o QT é notado que a forma de determinados *clusters* é incompatível com o formato das massas, pois são alongados ou retorcidos demais. Portanto para a próxima etapa tais *clusters* são eliminados ocasionando a seleção dos melhores candidatos à massa através da análise das características geométricas propostas feitas por um classificador MVS. A Figura 35e mostra os *clusters* eliminados de acordo com suas formas pintados de branco.

Figura 35: Primeiro estudo de caso: (a) Imagem com lesão demarcada pelo especialista, (b) imagem com fundo removido, (c) imagem realçada, (d) imagem segmentada pelo QT, (e) imagem com *clusters* removidos pintados de branco e (f) imagem com massa detectada corretamente.



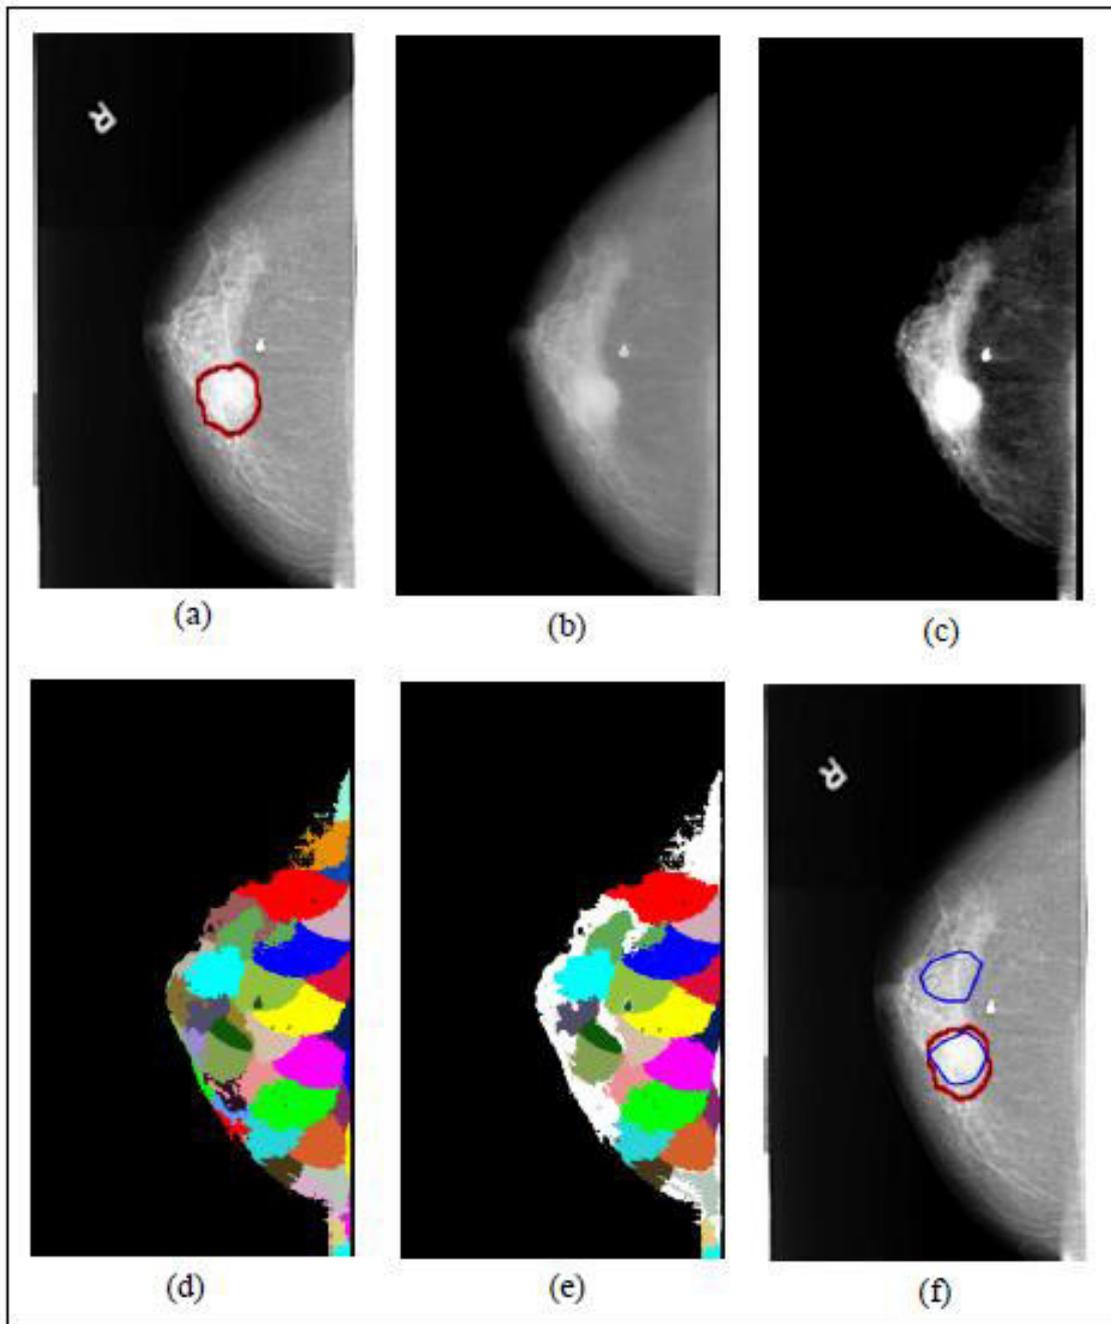
Assim somente os *clusters* considerados como massa na fase anterior têm suas características de textura extraídas pelos descritores de Haralick (Seção 3.4.11.2) e da função correlograma (Seção 3.4.12.1). Através da classificação MVS, são indicados os *clusters* classificados como massa finalizando assim o processo de detecção. Na Figura 35f é observada a detecção bem sucedida com a massa circuncidada em azul coincidindo com a indicação do radiologista.

5.3.2 Segundo caso

A imagem mamográfica utilizada para esta análise foi a do caso: B_3387_1.RIGHT_CC, do volume câncer 15, da base DDSM que esta representada na Figura 36a, nela a massa presente está identificada pelo especialista com um contorno vermelho. Novamente na etapa de pré-processamento o fundo da imagem com objetos indesejáveis são retirados (Figura 36b) e é feito um realce das estruturas internas da mama com as mesmas técnicas utilizadas para o primeiro caso de estudo. O resultado pode ser observado na Figura 36c. Para a segmentação também foi usado o QT com os mesmos parâmetros citados anteriormente (Figura 36d).

O pós-processamento com a redução dos candidatos à massa também ocorreu através da análise do classificador MVS nas características geométricas. O resultado pode ser observado na Figura 36e onde os *clusters* não considerados como massa por essa etapa estão pintados de branco.

Figura 36: Segundo estudo de caso: (a) Imagem com lesão demarcada pelo especialista, (b) imagem com fundo removido, (c) imagem realçada, (d) imagem segmentada pelo QT, (e) imagem com clusters removidos pintados de branco e, (f) imagem com massa detectada corretamente e outra detectada erroneamente.



Os *clusters* de massas da fase anterior têm suas características de texturas extraídas através dos descritores de Haralick em conjunto com a função correlograma para serem classificados através da MVS. O resultado dessa classificação indicara qual ou quais dele(s) corresponde a *massa*. Na Figura 36f, é exibido os *clusters* de massa envoltos por um fecho convexo azul.

Neste caso, é observado que a metodologia detectou a massa indicada pelo especialista, mas também apontou outra estrutura que não é *massa* como sendo massa. Nesta situação, é observado que até a região erradamente detectada como *massa* passou pela etapa de redução dos candidatos à massa (pós-processamento), pois a mesma possui o formato “arredondado” típico das massas, logo a falha não esta nessa etapa. Mas, além de ter o formato aceitável, tem seus níveis de cinzas bem parecido com o da região que o sistema detectou como massa, logo a falha ocorreu durante a classificação, pois com o modelo MVS utilizado pelo classificador o mesmo não conseguiu distinguir que aquele cluster não era de uma *massa*.

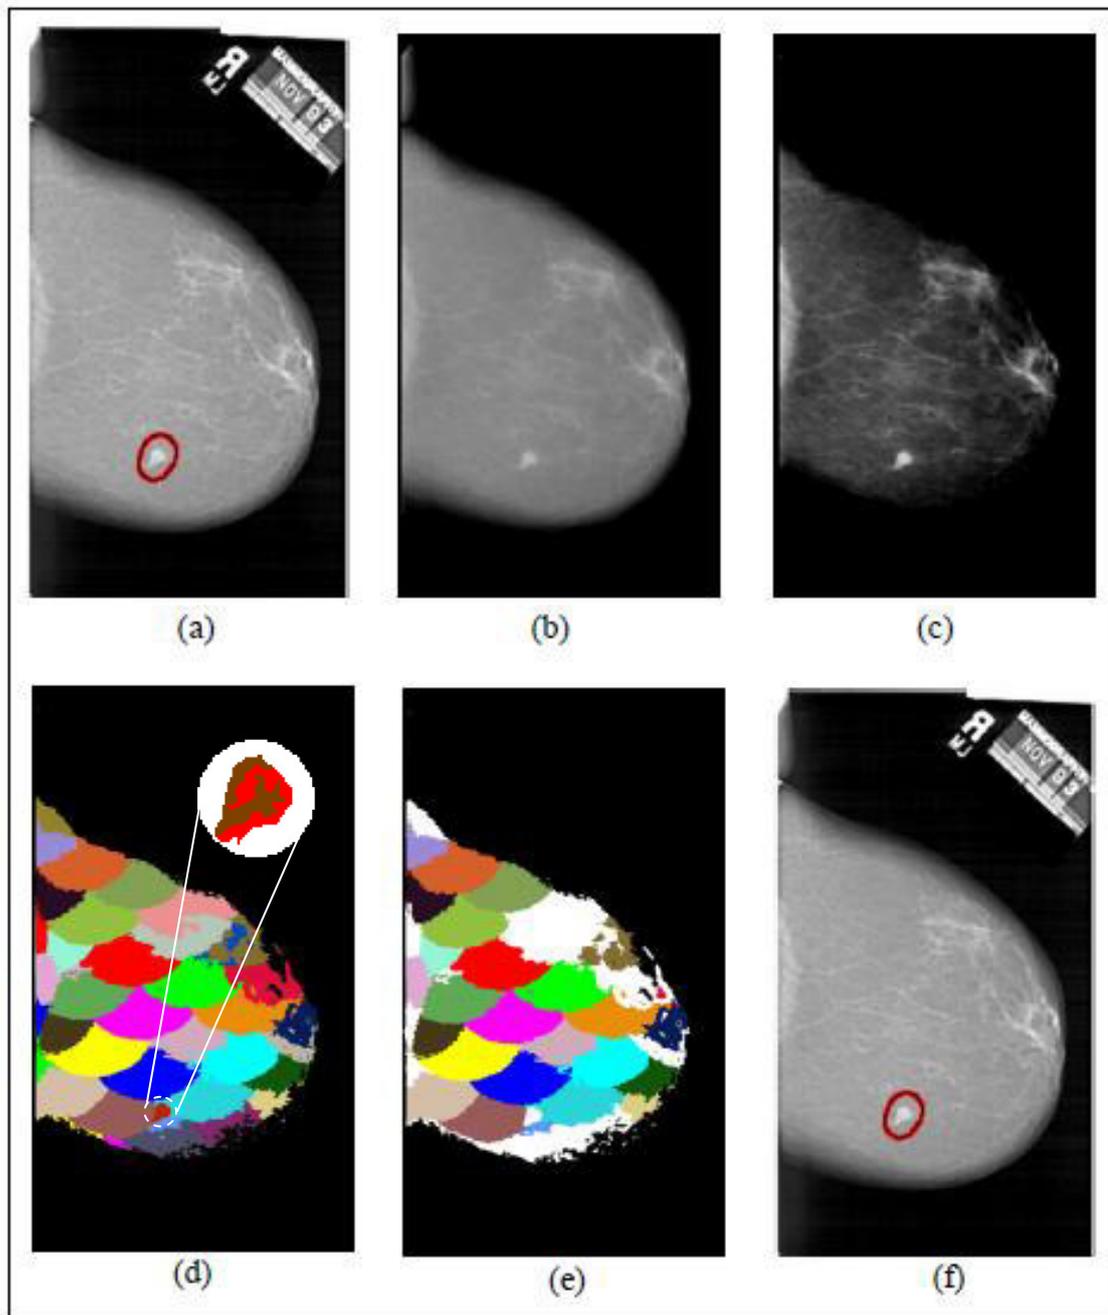
5.3.3 Terceiro caso

Neste terceiro caso, a metodologia não foi capaz de detectar a lesão na imagem mamográfica que a possui segundo o especialista, ou seja, houve uma falha total no processo de detecção. A imagem mamográfica utilizada para este caso foi a A_1412_1.RIGHT_CC, do volume benigno 07, da base DDSM pode ser observada na Figura 37a, na qual novamente esta demarcada a lesão com um contorno vermelho inserido pelo especialista.

Mais uma vez, através do pré-processamento, a imagem passa por um processo de retirada dos objetos que não pertencem à mama em si (Figura 37b) e um melhoramento para realçar os elementos da mama (Figura 37c) utilizando as técnicas já citadas acima. A segmentação mais uma vez foi feita através do algoritmo de clusterização QT e o resultado pode ser observado na Figura 37d, um destaque para a massa segmentada também é inserido. Mais uma vez, os *clusters* candidatos à massa são reduzidos através do uso de medidas geométricas conjuntamente com o classificador MVS. Os *clusters* eliminados estão pintados de branco na Figura 37e.

Os *clusters*, considerados como candidatos a massa pela etapa anterior, tem suas características de textura extraída através dos descritores de Haralick em conjunto com a função correlograma; sendo que essas, em seguida, são classificadas pelo MVS.

Figura 37: Terceiro estudo de caso: (a) Imagem com lesão demarcada pelo especialista, (b) imagem com fundo removido, (c) imagem realçada, (d) imagem segmentada pelo QT com um destaque para massa segmentada, (e) imagem com *clusters* removidos pintados de branco e, (f) imagem com falha total na detecção da massa



Observa-se na Figura 37f que o processo de detecção não conseguiu localizar nenhuma massa na imagem mamográfica, ou seja, houve uma falha total na detecção. É notado que o motivo que levou a tal situação é que a região que representa a massa não foi bem segmentada, ou seja, o QT particionou a massa em 2 *clusters* (que estão destacados na Figura 38d) e todos eles acabaram tendo formatos não compatíveis com as massas para passarem pela etapa de redução de candidatos as mesmas. Logo como esses *clusters* ficaram

retidos nessa etapa e na imagem não tinha outros com características texturais para a MVS entender como sendo lesão e indicar uma falsa lesão, o processo de detecção não conseguiu identificar nenhuma massa nessa mamografia.

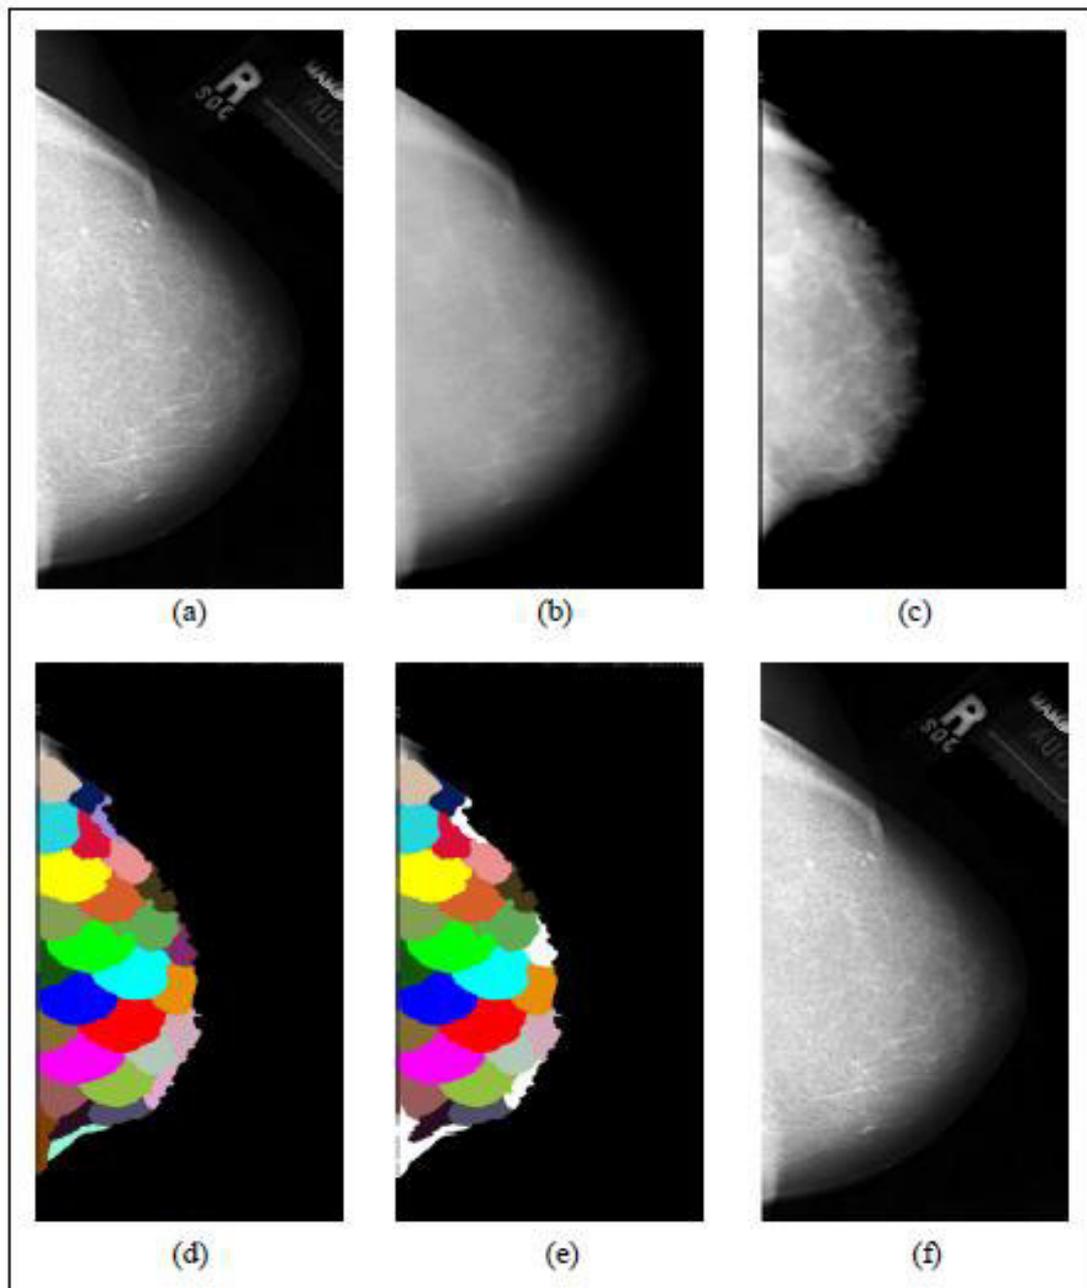
5.3.4 Quarto caso

Neste quarto caso, a metodologia obteve um bom desempenho ao não detectar nenhuma massa o que era esperado, pois a imagem utilizada era de uma mama *normal*. A imagem mamográfica utilizada para este caso foi a A_0255_1.RIGHT_CC, do volume normal 02, da base DDSM pode ser observada na Figura 38a, na qual também esta localizada a lesão com um contorno vermelho colocado pelo especialista.

Novamente, através do pré-processamento, a imagem passa por um processo de retirada dos elementos dispensáveis (Figura 38b) e um realce das estruturas internas da mama (Figura 38c) utilizando as técnicas já mencionadas. A segmentação novamente foi realizada pelo algoritmo de clusterização QT (Figura 38d). Novamente, os melhores clusters candidatos à massa são selecionados através do uso de medidas de forma conjuntamente com o classificador MVS. Os *clusters* eliminados nessa fase estão pintados de branco na Figura 38e.

Os *clusters*, resultantes da etapa anterior, têm suas características de textura extraídas através dos descritores de Haralick em conjunto com a função correlograma; sendo essas em seguida classificadas pelo MVS. O resultado da detecção pode ser observado na Figura 38f, em que na imagem original DDSM não foi detectada nenhuma massa, o que já era esperado para esse caso.

Figura 38: Quarto estudo de caso: (a) Imagem *normal*, (b) imagem com fundo removido, (c) imagem realçada, (d) imagem segmentada pelo QT, (e) imagem com *clusters* removidos pintados de branco e, (f) imagem *normal* sem massa detectada.



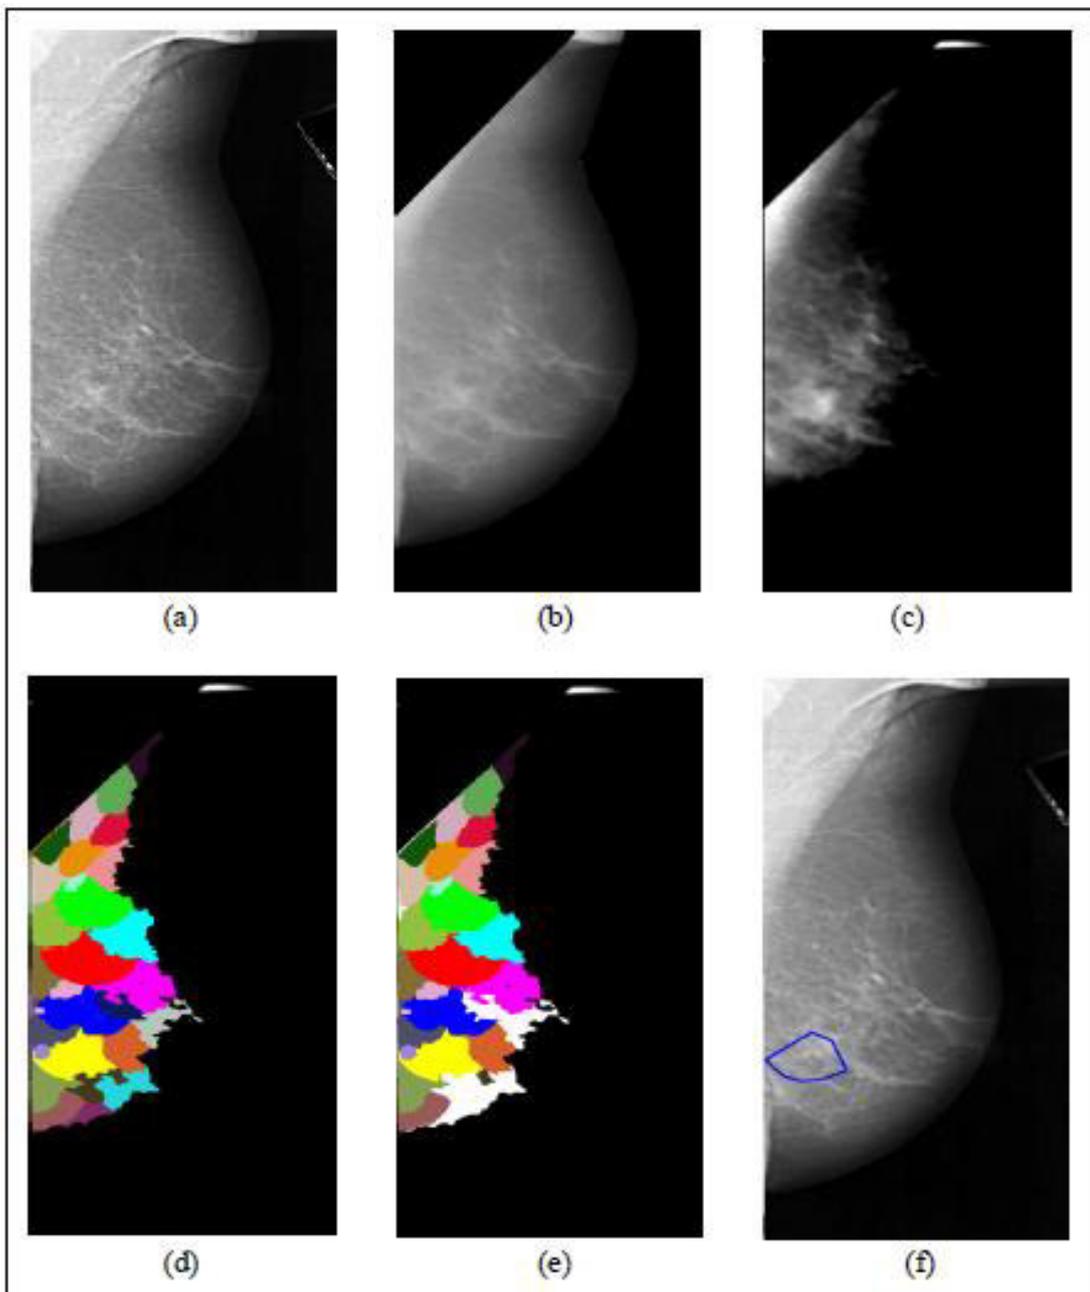
5.3.5 Quinto caso

Nesse ultimo caso de estudo a metodologia falhou ao detectar uma massa inexistente, já que a imagem analisada era de uma mama *normal*. A mamografia utilizada para este caso foi a A_0246_1.RIGHT_MLO, do volume *normal* 02, da base DDSM que pode ser observada na Figura 39a. Por se tratar de mais uma imagem *normal* não tem indicação de massa pelo especialista. Mais uma vez é utilizado um pré-processamento para retirada do

fundo e elementos não desejados da imagem (Figura 39b), é realizado um realce da mama com as mesmas técnicas utilizadas nos outros casos de estudo, sendo que o resultado pode ser observado na Figura 39c. Para a segmentação também foi usado o QT (Figura 39d).

O pós-processamento para seleção dos melhores candidatos à massa também ocorreu através da análise das medidas de forma conjuntamente com a MVS. O resultado pode ser observado na Figura 39e onde os *clusters* não considerados como *massa* por essa etapa estão pintados de branco.

Figura 39: Quinto estudo de caso: (a) Imagem *normal*, (b) imagem com fundo removido, (c) imagem realçada, (d) imagem segmentada pelo QT, (e) imagem com *clusters* removidos pintados de branco e, (f) imagem *normal* com massa inexistente detectada.



Neste caso, é observado, na Figura 39f, que a metodologia detectou uma massa em uma imagem mamográfica que não tem massas, ou seja, em uma mamografia *normal*. Nesta situação, é notado que a região detectada erradamente como sendo massa passou pela etapa de seleção dos melhores candidatos à massa, à medida que a mesma possui o formato “circular” típico das massas. Mas é observado que o cluster detectado como *massa* ficou com seus níveis de cinzas “parecidos” com os dessa lesão após o pré-processamento (Figura 40c) o que levou a MVS a não conseguir classificar aquele cluster como uma *não-massa*, ou seja, houve um erro de classificação.

5.4 Comparação com os resultados dos trabalhos relacionados

Nesta seção é feita uma comparação entre a metodologia proposta e os trabalhos relacionados no Capítulo 2 para se ter uma ideia da qualidade do trabalho aqui apresentado. Vale destacar que para se realizar uma comparação fidedigna com os trabalhos desse capítulo, seria necessário a utilização de uma mesma base, uma mesma resolução de bits por pixel, uma mesma quantidade de dados para o treinamento, validação do MVS e teste, etc.

Na Tabela 13, temos a comparação dos resultados da metodologia proposta com os resultados das metodologias abordadas no Capítulo 2.

Tabela 13: Comparação entre os resultados da metodologia proposta e os das metodologias citadas no Capítulo 2.

Metodologia	Base	S (%)	E (%)	A (%)	AUC	FPI	ASCROC
Martins <i>et al</i> (2007)	DDSM	-	-	99,39	1	-	-
Martins <i>et al</i> (2009a)	DDSM	89,30	-	-	-	0,93	-
Martins <i>et al.</i> (2009b)	DDSM	-	-	85	-	-	-
Nunes (2009)	DDSM	83,24	84,14	83,94	-	0,55	-
Mariusz <i>et al.</i> (2010)	Proprietária	-	-	-	0,9	-	-
Xiaoming <i>et al.</i> (2011)	DDSM	76,8	-	-	-	1,36	-
Mutaz (2011)	DDSM	91,67	84,17	-	-	-	-
Abdalla e Mutaz (2011)	DDSM	-	-	95,85	-	-	-
Mini (2011)	MIAS	58	-	60	-	-	-
Abubaker (2012)	MIAS	-	-	94	-	0,05	-
Hussain e Khan (2012)	DDSM	-	-	98,8	-	-	-
Hussain <i>et al.</i> (2012)	DDSM	-	-	99,5	-	-	-
Metodologia proposta	DDSM	92,31	82,2	83,53	-	1,12	0,8033

Algumas das metodologias citadas na Tabela 13 utilizam a sensibilidade como métrica de desempenho de detecção, sendo que a metodologia proposta alcançou uma boa

sensibilidade de 92,31% e conforme observado foi a maior das sensibilidades entre os trabalhos relacionados. Essa métrica é importante para medir o quanto o sistema é capaz de detectar massas.

Poucas metodologias utilizam a especificidade como métrica de validação de desempenho o que inviabiliza saber a capacidade de tais metodologias em acertar as ROIs que são *não-massas*. Na metodologia proposta, a especificidade alcançou um valor de 82,2% que pode ser considerada aceitável.

Com relação à acurácia de 83,53%, embora sendo uma das menores ficando a frente apenas da obtida por Mini (2011) de 60%, é considerada satisfatória levando em consideração que a base de teste utilizada na metodologia proposta era composta de 59 imagens com massa e 41 imagens *normais*. Logo, com o elevado número de imagens *normais* no teste é compreensível que se tenha, também, um alto número de clustes de *não-massas* que faz o número de FPI subir. Sendo que isso tem por consequência o valor da especificidade diminuir, e esse finalmente induz ao decaimento da acurácia.

Conforme observado na Tabela 6, dois trabalhos utilizaram a área sob a curva ROC como medida de desempenho o que não ocorreu no presente trabalho e nem nos demais. Ainda com relação ao citado sobre a quantidade de imagens *normais* presentes na base de teste, a taxa de FPI de 1,12 é considerada um valor compatível com os das demais metodologias.

Nenhuma das outras metodologias utilizou a área sob a curva FROC (ASCFROC) que nesta metodologia alcançou um valor de 0,8033. Isso significa que são necessários mais estudos sobre a qualidade das técnicas de medidas de desempenho do processo de detecção de lesões.

6 CONCLUSÃO

Nas últimas décadas, o número de casos de câncer aumentou significativamente se tornando um grande problema de saúde pública mundial. Sendo que esse aumento é percebido de maneira mais severa nos países pobres e emergentes.

O câncer de mama, entre as mulheres, é um dos mais frequentes no mundo e no Brasil as taxas de mortalidade por causa dessa doença continuam bastante elevadas, sendo que isso se dá porque normalmente a doença é diagnosticada em estágios avançados.

O presente trabalho propôs uma metodologia para detecção automática de massas em mamografias digitais. As etapas constam de um pré-processamento para realce das imagens com filtro passa-baixa, um aumento da escala de contraste e um realce com a Transformada de Wavelet (WT), uma clusterização com Quality Threshold (QT), depois um pós-processamento para redução dos candidatos a massa através das medidas geométricas em conjunto com a MVS e em seguida a extração das características de texturas feita com os descritores de Haralick e a função correlograma e por fim a classificação realizada com a MVS.

Algumas das vantagens da metodologia proposta são: a capacidade de realizar a detecção, totalmente automática, de lesões nas mamas a partir do exame mamográfico digital com uma precisão aceitável em relação aos sistemas CADs; também constitui uma importante contribuição para as literaturas relacionadas a essa área. Além de poder ser uma técnica utilizada pelos especialistas para o auxílio nas análises das mamografias digitais.

Os resultados alcançados neste trabalho mostram um desempenho aceitável da metodologia desenvolvida. Com uma configuração de 1423 *clusters* para treino da MVS (70%) e 610 *clusters* para validar o modelo (30%), foi alcançado o melhor modelo MVS para testar os novos exames. Na etapa de teste com 100 novos exames, sendo 59 com massas e 41 *normais* foi alcançado uma sensibilidade de 92,31%, uma especificidade de 82,2%, uma taxa de FPI de 1,12 e uma ASCFROC de 0,8033.

Apesar dos resultados alcançados com a metodologia proposta serem considerados aceitáveis, alguns aspectos podem ser aperfeiçoados, e isso certamente proporcionará resultados ainda melhores. Um dos aspectos diz respeito à etapa de segmentação com o QT, em que a escolha do diâmetro a ser utilizado para formação dos *clusters* nem sempre é satisfatório; sendo que às vezes são muito pequenos não abrangendo toda a massa, ou muito grandes formando *clusters* que englobam a massa, pequena para o

respectivo diâmetro, e outras regiões de *não-massas* em um mesmo cluster. Uma melhoria a ser feita seria a implementação de um diâmetro dinâmico que de alguma maneira se adequaria ao tamanho da região segmentada. Outro aspecto que poderia ser melhorado diz respeito ao pós-processamento com medidas geométricas em conjunto com a MVS para redução de candidatos a massa, pois é observado que alguns *clusters* “retorcidos” acabem passando para próxima etapa ao invés de serem eliminados nessa. Poder-se-ia utilizar descritores de bordas como curvatura, energia de deformação etc. em conjunto com os descritores de forma.

Além das melhorias citadas acima, outras ideias surgiram durante o desenvolvimento desta metodologia, mas devido ao tempo não puderam ser implementadas neste trabalho, ficando então como dicas para trabalhos futuros conforme relacionados abaixo:

- ✓ Utilizar a presente metodologia para detecção de microcalcificações;
- ✓ Usar métodos de realce no domínio da WT que redistribuem os coeficientes utilizando funções não lineares, também, sugeridas em (VIDAURAZAGA *et al.*, 2000);
- ✓ Pesquisar outras medidas de texturas para caracterização das massas;
- ✓ Classificar as massas detectadas em malignas ou benignas;
- ✓ Utilizar o classificador MVS em conjunto com o classificador Adaboost;
- ✓ Verificar o uso do QT na segmentação de outras imagens médicas como mamografias térmicas, ressonância magnética, ultrassonografias etc.
- ✓ Analisar o uso de outros filtros na etapa de pré-processamento em conjunto ou substituindo o filtro passa-baixa.
- ✓ Testar a metodologia em outro banco de mamografias como, por exemplo, o MIAS.

REFERÊNCIA

- ABUBAKER, A. Mass lesion detection using wavelet decomposition transform and support vector machine. **International journal of computer science & information Technology**. v. 4, n. 2, 2012.
- ANGELO, Michele Fúlvia. **Sistema de processamento de imagens mamográficas e auxílio ao diagnóstico via-internet**. Tese de Doutorado. Pós-graduação em Engenharia Elétrica, USP, Departamento de Engenharia Elétrica. São Carlos, 2007
- AZEVEDO, C. M. **Radiologia da mama**. Rio de Janeiro: INCA, 1994.
- BAJGER, M.; MA, F. ; WILLIAMS, S.; BOTTEMA, M. J.. Mammographic mass detection with statistical region merging. **Digital image computing: techniques and applications**, 2010. Disponível em:
<http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=5692535&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs_all.jsp%3Farnumber%3D5692535>. Acesso em: 11 dez. 2012.
- BALLARD, D. H.; BROWN, C. M. **Computer vision**. Nova Jersey: Prentice Hall, 1982. Disponível em: <<http://homepages.inf.ed.ac.uk/rbf/BOOKS/BANDB/bandb.htm>>. Acesso em: 22 dez. 2012.
- BANKMAN, I. N. **Handbook of medical imaging: processing and analysis**. [S. l.]: Academic Press, 2000.
- BARALDI, A.; PARMIGGIANI, F. An investigation of the textural characteristics Associated with Gray Level Co-occurrence Matrix Statistical Parameters. **IEEE Transactions on Geoscience and Remote Sensing**, p. 293–304, 1995. Disponível em:
<http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=377929&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs_all.jsp%3Farnumber%3D377929>. Acesso em: 10 dez. 2012.
- BÄSSMAN, H.; KREYSS, J. **Bildverarbeitung ad oculus**. [S. l.]: Heidelberg Springer, 1998.
- BICK, U.; MARYELLEN L. G.; SCHMIDT R. A.; NISHIKAWA R. M.; WOLVERTON D. E. DOI, K. Automated segmentation of digitized mammograms. **Academic Radiology**., v. 2, n. 1, p. 1- 9, 1995. Disponível em:
<<http://www.sciencedirect.com/science/article/pii/S1076633299801159>>. Acesso em: 20 dez. 2012.
- BORGES, V. R. P.; GULIATO, D. **Segmentação da mama: detecção do contorno externo e extração do músculo peitoral**. 2008. Disponível em:
<<https://ssl4799.websiteseuro.com/swge5/seg/cd2008/PDF/IC2008-0532.PDF>>. Acesso em: 21 dez. 2012.
- BRAZ JÚNIOR, G. **Identificação de massas em mamografias usando textura, geometria e algoritmos de agrupamento e classificação**. 2006. Monografia (Graduação) - Universidade

Federal do Maranhão, Departamento de Ciência da Computação. São Luís, 2006. Disponível em: <http://www.tedebc.ufma.br/tde_arquivos/10/TDE-2008-05-14T151628Z-146/Publico/Geraldo%20Braz%20Junior.pdf>. Acesso em: 20 dez. 2012.

_____. Density correction of peripheral breast tissue on digital mammograms. **Radiographics**, v. 16, n. 6, p.1403-1411, 1996. Disponível em: <<http://radiographics.rsna.org/content/16/6/1403.full.pdf>>. Acesso em: 21 dez. 2012.

BURGES, C. J. C. A tutorial on support vector machines for pattern recognition. *Knowledge Discovery and Data Mining*, v. 2, n. 2, p.1-43, 1998.

BYNG, J. W.; CRITTEN, J. P. YAFFE, M. J. Thickness-equalization processing for mammographic images. **Radiology**, v. 203, n. 2, p. 564-568, 1997. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/9114122>>. Acesso em: 26 jan. 2012.

KIMME, C; BALLARD, D.; SKLANSKY, J. (1975). **Finding circles by an array of accumulators**. *Communication of the ACM* 18(2).

CANNY, J. A. Computational approach to edge detection, *IEEE trans. Pattern Analysis and Machine Intelligence*, v. 8, p. 679-714, 1986. Disponível em: <http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=4767851&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs_all.jsp%3Farnumber%3D4767851>. Acesso em: 21 dez. 2012

CHAKRABARTI, J. EVANS AJ, JAMES J, ELLIS IO, PINDER SE, MACMILLAN RD. Accuracy of mammography in predicting histological extent of carcinoma ductal in situ (DCIS). **European Journal of Surgical Oncology**, Amsterdam, v. 32, n. 10, p. 1089-1092, 2006.

CHAKRABORTY D. P; WINTER, L. H. L, Free-response methodology: alternate analysis and a new observer-performance experiment. **Radiology** 1990; n. 174, p. 873-881.

CHAU, C.; SIU, W. Generalised Hough transform using regions with homogeneous color. **International Journal of Computer Vision**, v. 59, p. 183-199, 2004.

CHEN, T. K.; CHUNG. An efficient randomized algorithm for detecting circles. **Computer Vision and Image Understanding**, v. 83, p. 172-191, 2001. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.19.8995>>. Acesso em: 21 dez. 2012.

CHENG, H. D.; CAI, X; CHEN, X.; HU, L. LOU, X. Computer-aided detection and classification of microcalcification in mammograms: a survey. **Pattern recognition**, v. 36, p. 2937-2991, 2003. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0031320303001924>>. Acesso em: 20 dez. 2012.

CLARK, I. **Practical geostatistics**. London: Applied Science Publishers Ltd. 1979. Disponível em: < <http://www.edumine.com/courses/short-courses/practical-geostatistics/>>. Acesso em: 21 dez. 2012.

CRESSIE, N. **Statistics for spatial data**. New York: Wiley, 1993.

DDSM, M. **The digital database for screening mammography, in proceedings of the fifth international workshop on digital mammography, medical physics publishing**. 2001. Disponível em: <<http://marathon.csee.usf.edu/Mammography/Database.html>>. Acesso em: 20 dez. 2012.

DENGLER, J.; BEHRENS, S.; DESAGA, J. F. Segmentation of microcalcifications in mammograms. **IEEE Trans. Med. Imaging**, v. 12, p. 634-642, 1993. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/18218457>>. Acesso em: 09 de set. 2012.

DODONOV, E.; MELLO, R. F. de. **Estudo sobre abordagens de extração, classificação e predição de comportamento de processos**. São Paulo: ICMC-USP, 2008.

DOI, K. Overview on research and development of computer-aided diagnostic schemes. **Seminars in Ultrasound, CT and MRI**, v. 25, p. 404-410, 2004. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/15559123>>. Acesso em: 21 dez. 2012.

DUDA, R.; HART, P. Use of the hough transformation to detect lines and curves in the pictures. **Communication Association Computing Machine**. v. 15, p. 11-15, 1972. Disponível em: <<http://dl.acm.org/citation.cfm?id=361242>>. Acesso em: 21 dez. 2012.

FÁTIMA, A. R.; JORGE1, R. N.; TAVARES, JOÃO M.R.S.; FERREIRA, A.J.M. MASCARENHAS, T.; RANIA F. EL S.; FERNANDES, A. A.; FERNANDA GENTIL, CONGRESSO DE MÉTODOS NUMÉRICOS EM ENGENHARIA, 2007, [S. I.]. **Anais...**, [S. I.], 2007. Disponível em: <<http://repositorio-aberto.up.pt/handle/10216/356>>. Acesso em: 20 dez. 2012.

FERNANDES, L.A.F.; OLIVEIRA, M.M., "A general framework for subspace detection in unordered multidimensional data," *Pattern Recognition, Elsevier, Volume 45, Issue 9*, pp. 3566–3579 (September, 2012)

FRANK, E. D.; DICKERSON, L. N. Mamografia. In: BONTRANGER, L. K. **Tratado de técnica radiológica e base anatômica**. Rio de Janeiro: Guanabara Koogan, 2003. cap. 18. p. 575-591.

GAVRIELIDES, M. A. L. O. J. Y.; VARGAS-VORACEK, R.; FLOYD, C. E. Segmentation of suspicious clustered microcalcifications in mammograms. **Medical Physics**, v. 27, n. 1, p.13-22, 2000. Disponível em: <http://online.medphys.org/resource/1/mphysa6/v27/i1/p13_s1?isAuthorized=no>. Acesso em: 10 dez. 2012.

GIGER, M. L.; MACMAHON, H. Image processing and computer-aided diagnosis. **Radiologic Clinics of North America**, v. 34, n. 3, p. 565-595, 2000. Disponível em: <ftp://ftp.inf.puc-rio.br/pub/docs/techreports/02_09_silva.pdf>. Acesso em: 15 dez. 2012.

GONÇALVES, A. R. **Máquina de vetores suporte**. 2009. Disponível em: <www.dca.fee.unicamp.br/~andreric>. Acesso em: 15 dez. 2012.

GONZALES, R. C.; WOODS, R. E. Digital image processing. **Addison-Wesley**, 1992.

Disponível em: <<http://pt.scribd.com/doc/41647648/Gonzales-R-C-Woods-R-E-Digital-Image-Processing-2ed-PH-2001-400dpi-T-C-ISBN-0201180758-813s-CsIp->>. Acesso em: 11 dez. 2012.

GORDON, A. D. **Classification**. 2. ed. London: Chapman e Hall, 1999.

HADDAD, N. S. M. B. Mortalidade por neoplasmas em mulheres em idade reprodutiva - 15 a 49 anos - no estado de São Paulo, Brasil, de 1991 a 1995. **Rev. Assoc. Med. Bras.**, v. 47, n. 3, p. 221-230, 2001. Disponível em: <http://www.scielo.br/scielo.php?pid=S0104-42302001000300034&script=sci_arttext>. Acesso em: 12 dez. 2012.

HAYKIN, S.; ENGEL, Paulo Martins. **Redes neurais: princípios e prática**. 2. ed., Bookman. Hamilton, 2008.

_____. **Neural Networks** - a comprehensive foundation. Prentice-Hall, New Jersey, 2nd edition, 1999.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification, 1973 – IEEE Transactions on Systems. **Man and Cybernetics**, v. 3, p. 610-620, 2007. Disponível em: <http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=4309314&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs_all.jsp%3Farnumber%3D4309314>. Acesso em: 15 dez. 2012.

HEATH, M.; BOWYER, K. W.; KOPANS, D. **Current status of the digital database for screening mammography**: digital mammography. Proceedings of the Fourth International Workshop on Digital Mammograph. Netherlands: Kluwer Academic Publishers, 1998. p. 457 – 460. Disponível em: <<http://dl.acm.org/citation.cfm?id=2100445>>. Acesso em: 15 dez. 2012.

HOUGH. P. **Method and means for recognizing complex patterns**. U.S Patent 3 069 654, Dec, 1962.

HOUGH, P. Method and means for recognizing complex patterns. **U. S. Patent**, v. 3, p. 069-654, dec. 1962. Disponível em: <https://www.google.com.br/search?hl=pt-BR&tbo=d&noj=1&biw=1920&bih=942&q=Method+and+means+for+recognizing+complex+patterns.&oq=Method+and+means+for+recognizing+complex+patterns.&gs_l=serp.3..0i30l3j0i5i30l2.1665.2521.0.2922.1.1.0.0.0.283.283.2-1.1.0...0.0...1c.1.a9tcmnrGI4M>. Acesso em: 16 dez. 2012.

HUSSAIN, M.; KHAN, S.; MUHAMMAD, G. BEBIS, G. Mass detection in digital mammograms using Gabor filter bank. **Image Processing Conference**, London, 2012.

HUSSAIN, M.; KHAN, N. **Automatic mass detection in mammograms using multiscale spatial Weber local descriptor**. Austria: Conference Publications, 2012. p. 11-13.

ILLINGWORTH, J.; KITTLER, J. **A survey of the Hough Transform**; *Computer Vision, Graphics, and Image Processing*, Vol. 44, No. 1, pp. 87-116, ISSN: 0734189X, 1988.

INCA. Instituto Nacional Do Câncer. **Estimativas da incidência e mortalidade por cancer**

no Brasil. 2012. Disponível em: <<http://www.inca.gov.br/estimativa/2012/>>. Acesso em: 08 set. 2012.

ISAAKS, E. H.; SRIVASTAVA, R. M. **Applied geostatistics**. [S. l.: s. n.], 1990.

KANE, S. A. **Introduction to physics in modern medicine**. Second: Routledge, 2003.

KOPANS, D. B. **Imagem da mama**. Porto Alegre: MEDSI, 2000.

KULKARNI, A. D. **Artificial neural networks for image understanding**. Van Nostrand Reinhold: New York, 1995.

LEI, Y.; WONG, K. Ellipse detection based on symmetry. **Pattern Recognition**, v. 20, p. 41-47, 1999.

LEAVERS, V., *CVGIP: Image Understanding*, 58, 250-264. 1993.

LIBERMAN, L.; MENEL, J. H. Breast imaging reporting and data system (BI-RADS). **Radiol Clin North Am.**, New York, v. 40, n. 3, p. 409-430, 2002. Disponível em: <<http://www.birads.at/info.html>>. Acesso em: 20 dez. 2012.

LORENA, A. C.; CARVALHO, A. C. P. L. F. **Uma introdução às support vector machines**. 2007. Disponível em: <http://seer.ufg.br/index.php/rita/article/viewFile/rita_v14_n2_p43-67/3543>. Acesso em: 20 dez. 2012.

LUNA, Bráulio Filho. Utilização racional dos testes diagnósticos em cardiologia. **Casa da Cardiopatia Hipertensiva**, 2007. Disponível em: <<http://www.unifesp.br/dmed/cardio/ch/utiliza.htm>>. Acesso em: 15 dez. 2012.

MD.Saúde. **Fotos de doenças**. 2008. Disponível em: <<http://www.mdsaude.com/2008/01/.html>> . Acesso em: 25 nov. 2012.

MAKRISHNA, R. S.; GORDON, R. Detection of breast cancer at a smaller size can reduce the likelihood of metastatic spread: a quantitative analysis. **Acad Radiol, Association of University Radiologists**, Canadá, v. 4, n. 1, p. 8-12, 1997.

MARTINAZZI, E. **Detecção de pequenas microcalcificações para auxílio no diagnóstico precoce de câncer de mama**. 2008. Dissertação (Mestrado em Física) - Faculdade de Física, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2008.

MARTINS, L. O.; SILVA, A. C.; DE PAIVA, A. C.; GATTASS, M. Detection of breast masses in mammogram images using growing neural gas algorithm and ripley's k function, *J. Signal Process. Syst.* 55 (1-3) (2009a) 77-90.

MARTINS, L. O.; SILVA, A. C.; DE PAIVA, A. C.; GATTASS, M.; JUNIOR, G. B. Detection of masses in digital mammograms using k-means and support vector machine: electronic letters on computer vision and image. **Analysis**, p. 39-50, 2009b. Disponível em: <<http://ddd.uab.cat/pub/elcvia/15775097v8n2p39.pdf>>. Acesso em: 6 dez. 2012.

MARTINS, L. O.; SILVA, A. C.; DE PAIVA, A. C.; GATTASS, M.; SILVA, E. C.; Classification of breast masses in mammogram images using ripley's K function and support vector Machine. **Machine learning and data mining in pattern recognition lecture notes in computer science**, v. 4571, p. 784-794, 2007. Disponível em: <http://link.springer.com/chapter/10.1007%2F978-3-540-73499-4_59?LI=true>. Acesso em: 09 de set. 2012.

MELLO, C. A. B. **Morfologia matemática**. 2008. Notas de aula na Graduação em Engenharia da Computação – UPE.

MINI, M.G. **Neural network based classification of digitized mammograms**: neural network based classification of digitized mammograms, 2011. Disponível em: <<http://dl.acm.org/citation.cfm?id=2107558&dl=ACM&coll=DL&CFID=264990490&CFTOKEN=48670982>>. Acesso em: 10 set. 2012.

MONTEIRO, A. A. **Estimação de curva de juros a vista**: microestrutura dos contratos e restrição do formato da curva a termo. [200-?]. Disponível em: <<http://bibliotecadigital.fgv.br/ocs/index.php/ebf/4EBF/paper/viewFile/1546/665>>. Acesso em: 21 dez. 2012.

MORERA, A. F.; ESTEVE, M. F.; SOTERAS, J. M. T. Breast turners: composition of microcalcifications. **Radiology**, p. 325-327, 2007. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/2845471>>. Acesso em: 09 dez. 2012.

MUTAZ, A. L.; ABDALLA, M.; DRESS, S.; ZAKI, N. Masses detection in digital mammogram by gray level reduction using texture coding method. **International Journal of Computer Applications**, v. 29, p. 19, 2011.

MUTAZ, A. L.; DERIS, S., ZAKI, N. M. Detection of masses in digital mammogram using second order statistics and artificial neural network. **International Journal of Computer Science & Information Technology**, v. 3, n. 3, 2011.

NISHIKAWA, R. M.; GIGER M. L.; DOI K.; METZ C. E.; YIN F. F.; VYBORNÝ C. J.; SCHMIDT R. A. Effect of case selection on the performance of computer-aided detection schemes. **Medical Physics**, v. 21, p. 265-269, 1993. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/8177159>>. Acesso em: 8 dez. 2012.

NUNES, F. L. S. **Detecção de massas em imagens mamográficas usando índice de diversidade de Simpson e máquina de vetores de suporte**. 2009. Tese (Mestrado) - Departamento de Engenharia Elétrica, Universidade Federal do Maranhão, São Luís, 2009. Disponível em: <<http://www.ppgee.ufma.br/aigaion/?page=search&command=search&keywords=Support+Vector+Machine>>. Acesso em: 09 set. 2012.

_____; SCHIABEL, H.; BENATTI, R. H. Contrast enhancement in dense breast images using the modulation transfer function. **Medical Physics**, v. 29, n. 12, p. 2925-2936, 2002.

OMS. Organização Mundial da Saúde. **Liga contra o câncer**. 2012. Disponível em: <<http://www.ligacontraocancer.com.br/tipos-de-cancer/cancer-de-mama/>>. Acesso em: 9 dez. 2012.

PADWAL, M. **Elements of breast imaging basics**. 2007. Disponível em: <http://www.gehealthcare.com/us/en/ultrasound/education/products/cme_breast.html>. Acesso em: 22 dez. 2012.

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

RANGAYYAN, R. M.; NGUYEN, T. M.; AYRES, F. J.; NANDI, A. K. Effect of pixel resolution on texture features of breast masses in mammograms. **Journal of digital imaging**. v. 23, 5 oct. 1997.

REICHARDT, K.; VIEIRA, S. R.; LIBARDI, P. L. **Variabilidade espacial de solos e experimentação de campo**. Campinas, SP: [s. n.], 1986.

SAMPAIO, W. B. de. **Deteção de massas em imagens mamográficas usando redes neurais celulares, funções geoestatísticas e máquinas de vetores de suporte**. 2009. Dissertação (Mestrado em Engenharia de Eletricidade) – Curso de Pós Graduação em Engenharia de Eletricidade, Universidade Federal do Maranhão, São Luís, 2009. Disponível em: <http://www.tedebc.ufma.br/tde_arquivos/10/TDE-2009-10-15T164242Z-337/Publico/Werner%20Borges%20de%20Sampaio.pdf>. Acesso em: 16 dez. 2012.

SCHWARTZ, W. R.; PEDRINI, H. Método para classificação de imagens baseada em matrizes de co-ocorrências utilizando características de textura. In: COLÓQUIO BRASILEIRO DE PESQUISAS GEODÉSICAS, 2003, [S. l.]. **Anais...** [S. l.], 2003. Disponível em: <<http://homepages.dcc.ufmg.br/~william/publications.html>>. Acesso em: 21 dez. 2012.

SCHOUTEN, T. **Image Processing**. Radboud University, Department of Computer Science. Disponível em <<http://www.cs.ru.nl/~ths/col/h9/9gebiedENG.html>>. Acesso em: 24 out. 2012.

SOUSA, J. R. F. S.; SILVA, A. C.; PAIVA, A. C. Lung structures classification using 3d geometric measurements and SVM. In: IBEROAMERICAN CONGRESS ON PATTERN RECOGNITION, 12., 2007, [S. l.]. **Anais...** [S. l.], 2007. Disponível em: <http://link.springer.com/chapter/10.1007%2F978-3-540-76725-1_81?LI=true.>. Acesso em: 15 dez. 2012.

SPRINGER. Integrating remote sensing and GIS by object-oriented data modelling. **Computers e Graphics**, may./jun. 1998. Disponível em: <http://link.springer.com/chapter/10.1007%2F978-90-481-8572-6_12>. Acesso em: 16 dez. 2012.

TAUBMAN, D. S.; MARCELLIN, M. W. **JPEG2000: image compression, fundamentals, standards and practice**. [S. l.]: Kluwer Academic Publishers, 2002.

TAYLOR, P. M.; CHAMPNESS, J.; GIVEN-WILSON, R. M.; POTTS, H. W.; JOHNSTON K. An evaluation of the impact of computer: based prompts on screen readers interpretation of mammograms. **British Journal of Radiology**, v. 77, p. 21-27, 2004.

THIJSEN, M. A. O. Aspectos físicos e técnicos da mamografia. In: DRONKERS, D. J.;

HENDRIKS, J. H. C. L.; HOLLAND, R.; ROSENBUSCH, G. **Mamografia prática: patologia-técnicas-interpretação-métodos complementares**. Rio de Janeiro: Revinter, 2003. cap. 5. p. 60-63.

THURFJELL, E. L.; LENERVALL, K. A.; TAUBE, A. A. Benefit of independent double reading in a population-based mammography screening program. **Radiology**, v. 191, p. 241 – 244, 1994. Disponível em: <<http://www.ncbi.nlm.nih.gov/pubmed/8134580>>. Acesso em: 20 dez. 2012.

TSUJI, S.; MATSUMOTO F. On detecting of ellipses by a modified hough transformation. **IEEE Transaction Computer**, v. 27, n. 8, 1978. Disponível em: <http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=1675191&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs_all.jsp%3Farnumber%3D1675191>. Acesso em: 16 dez. 2012.

VALLE, E. E. **Realce de imagens no domínio da transformada**. 2006. Dissertação (Mestrado em Engenharia Elétrica) - Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro, 2006. Disponível em: <http://www.maxwell.lambda.ele.puc-rio.br/Busca_etds.php?strSecao=resultado&nrSeq=8237@1>. Acesso em: 8 dez. 2012.

VALLE, J. C. do. **Câncer de mama locorregional Avançado**. Rio de Janeiro: MEDSI, 2006.

VASCONCELOS, Simone. **Matriz de co-ocorrência**. 2012. Disponível em: <<http://www.ic.uff.br/~aconci/co-ocorrencia.pdf>>. Acesso em: 15 Ago.2012.

VIDAURAZAGA, M.; DIAGO, L. A.; CRUZ, A. Contrast enhancement with wavelet transform in radiological images. **IEEE International Conference on Engineering in Medicine and Biology Society**, Chicago, v. 3, p. 1760-1763, jul. 2000.

VIEIRA, E.A.; MELO, R. H. C. **Granulometria: uma aplicação para contagem e medição de grãos em imagens digitais**. 2004. Monografia (Graduação em Ciência da Computação) - Universidade Federal Fluminense, Rio de Janeiro, 2004. Disponível em: <<http://repositorio-aberto.up.pt/handle/10216/43970>>. Acesso em: 16 dez. 2012.

VIEIRA, M. A. C.; ESCARPINATI, M.; SCHIABEL, H.; CAETANO, C. A. C.; NUNES, F. L. S. Segmentation technique for digital mammograms: saving processing time and memory. In: MEDITERRANEAN CONFERENCE ON MEDICAL AND BIOLOGICAL ENGINEERING AND COMPUTING, 9., [S. l.], 2001. **Proceedings...** [S. l.], jun. 2001.

VIEIRA, S. R.; REYNOLDS, W. D.; TOPP, G. C. Spatial variability of hydraulic properties in a highly clay soil. In: WIERENGA, P. J.; BACHELET, D. (Eds). **Validation of flow and transport models for the unsaturated zone: conference proceeding**. New Mexico State University: Departement of Agronomy and Horticulture, 1988. p. 23-26.

WITTEN, I. H; FRANK, E. **Data Mining: practical machine learning tools and techniques**. morgan kaufmann, San Francisco, CA, USA, second edition, 2005.

XIAOMING, L.; XU, X.; LIU, J.; FENG, Z. A new automatic method for mass detection in mammography with false positives reduction by supported vector machine. **BMEI**, p. 33-37,

2011. Disponível em:

<http://online.medphys.org/resource/1/mphysa6/v25/i6/p957_s1?isAuthorized=no>. Acesso em: 8 dez. 2012.

XU, L.; OJA, E. Randomized Hough transform. **Basic Mechanisms, Algorithms, and Computational Complexities**, CVGIP: Image Understanding, v. 57, n. 2, 1993. Disponível em: <<http://geocities.ws/jerojasrom/revisionart/rht.pdf>>. Acesso em: 8 dez. 2012.

XU, R.; WUNSCH, D. Survey of clustering algorithms. **IEEE Transactions on Neural Networks**, v. 16, n. 3, p. 645-678, 2005. Disponível em: <http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=1427769&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs_all.jsp%3Farnumber%3D1427769>. Acesso em: 9 dez. 2012.

ZIBREIRA, C. **Descrição e procura de vídeo baseadas na forma**. Portugal: Instituto Superior Técnico; Technical University of Lisbon, 2000.