

UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
CURSO DE CIÊNCIA DA COMPUTAÇÃO

André de Souza Moreira

*Metodologia para Detecção Automatizada de Massas em
Imagens de Mamografia através de Análise de Diversidade e
Algoritmos em Grafo*

São Luís - MA
2013

André de Souza Moreira

*Metodologia para Detecção Automatizada de Massas em
Imagens de Mamografia através de Análise de Diversidade e
Algoritmos em Grafo*

Monografia apresentada ao curso de Ciência da
Computação da Universidade Federal do Maranhão,
como parte dos requisitos necessários para a obtenção
do grau de Bacharel em Ciência da Computação.

Orientador: Prof. Ms. Geraldo Braz Junior

São Luís - MA

2013

Moreira, André de Souza

Metodologia para Detecção Automatizada de Massas em Imagens de Mamografia através de Análise de Diversidade e Algoritmos em Grafo / André de Souza Moreira - 2013

56.f

Impresso por Computador (fotocópia)

Orientador: Prof. Ms. Geraldo Braz Junior.

Monografia (Graduação) - Universidade Federal do Maranhão, Ciência da Computação, 2013.

1. Processamento de imagens – Câncer de mama. 2. Segmentação em grafo. 3. Índice de diversidade.. I.Título.

CDU 004.383.5:618.19-006

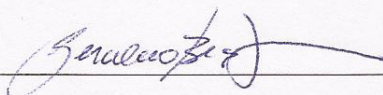
André de Souza Moreira

*Metodologia para Detecção Automatizada de Massas em
Imagens de Mamografia através de Análise de Diversidade e
Algoritmos em Grafo*

Monografia apresentada ao Curso de Ciência da
Computação da UFMA, como requisito parcial para
a obtenção do grau de BACHAREL em Ciência da
Computação.

Aprovado em 18 de fevereiro de 2013

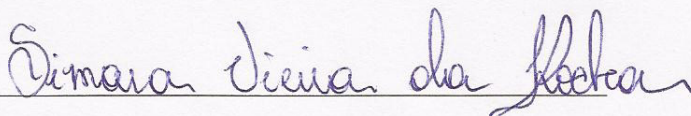
BANCA EXAMINADORA



Prof. Ms. Geraldo Braz Junior
Mestre em Ciência da Computação



Prof. Dr. Anselmo Cardoso de Paiva
Doutor em Informática



Prof^a. Ms. Simara Vieira da Rocha
Mestre em Ciência da Computação

Aos meus pais e irmã.

À minha querida Larissa Régia.

Aos meus amigos.

Resumo

O câncer de mama tem sido um dos tipos mais frequentes de câncer entre a população feminina. Neste grupo, esta neoplasia é a principal causa da morte entre mulheres de 35 a 55 anos de idade. Apesar de ainda não haver modos efetivos de prevenir o câncer de mama, o tratamento do câncer de mama em estágio inicial proporciona maiores chances de cura ao paciente, além de um tratamento menos agressivo. Por isso, a mamografia de rastreamento tem sido fundamental na detecção precoce desta neoplasia. Entretanto, alguns resultados destes exames são comprometidos por diversos fatores, entre eles a qualidade da imagem mamográfica. Neste cenário, a comunidade científica tem despendido esforços visando a construção de sistemas CAD e CADx a fim de dar suporte ao processo de detecção e diagnóstico do câncer de mama através de técnicas de processamento de imagens e visão computacional em imagens médicas. Este trabalho apresenta uma proposta de metodologia para a construção de um sistema CAD/CADx que auxilie o processo de detecção e diagnóstico de massas em imagens da mama utilizando segmentação baseada em grafo com cortes normalizados e índices de diversidade para a classificação com o auxílio de Máquinas de Vetores de Suporte.

Palavras-chaves: Câncer de Mama, CADx, Processamento de Imagens, Índices de Diversidade, Segmentação em Grafo.

Abstract

Breast cancer has been one of the most frequent types of cancer among the female population. In this group, this neoplasia is the leading cause of death for among women between 35 and 55 years of age. Although there is still no effective ways to prevent breast cancer, the treatment of breast cancer at an early stage provides greater chances of cure for the patient, and less aggressive treatment. For this reason, screening mammography has been instrumental in the early detection of this malignancy. However, some results of these tests are compromised by several factors, including the quality of the mammographic image. In this scenario, the scientific community has made efforts aimed to building CAD/CADx systems to support the process of detection and diagnosis of breast cancer using techniques of image processing and computer vision in medical imaging. This paper proposes a methodology for building a CAD/CADx to assist the process of detection and diagnosis of masses in breast imaging using graph-based segmentation with normalized cuts and diversity index for classification with the aid of Support Vector Machines.

Keywords: Breast Cancer, CADx, Image Processing, Diversity Index, Graph Segmentation.

Agradecimentos

Aos meus pais, Raimundo e Bernadete, pelo apoio e todo incentivo dado pela minha mãe.

Ao professor Anselmo Cardoso de Paiva pelos ensinamentos e pela confiança à mim depositada durante os anos como bolsista de Iniciação Científica.

Ao professor Geraldo Braz Júnior pela orientação, paciência, disposição e aos inúmeros conhecimentos que foram transmitidos à mim durante os anos de Iniciação Científica.

À professora Simara Vieira da Rocha por ter me guiado nos meus primeiros passos na área de processamento de imagens.

Aos demais professores do Departamento de Informática desta universidade.

Aos amigos e companheiros de laboratório que juntos fizemos projetos, planejamentos e discutimos sobre o futuro profissional.

À minha querida Larissa Régia pelo apoio, incentivo e estímulo que foram fundamentais para que meus objetivos se tornassem maiores.

Trabalhos publicados pelo Autor

MOREIRA, A. S. ; JUNIOR, G. B. ; ROCHA, S. V. ; SILVA, A. C. ; PAIVA, A. C. .
Segmentação Semi-Automática de Mamografias baseada em Clusterização em Grafo. In:
WIM - XII Workshop de Informática Médica, 2012, Curitiba. Anais do XII Workshop de
Informática Médica (WIM 2012), 2012.

MOREIRA, A. S. ; JUNIOR, G. B. ; ROCHA, S. V. ; SILVA, A. C. ; PAIVA, A. C. .
NCuts para Detecção de Massas Mamárias em Imagens de Mamografia. In: Encontro
Regional Ceará Maranhão e Piauí / Jornada de Informática do Maranhão, 2012, São Luís
- MA. Jornada de Informática do Maranhão, 2012.

MOREIRA, A. S. ; PAIVA, A. C. ; JUNIOR, G. B. .Detecção de Massas em Imagens
da Mama Usando Índices de Diversidade e Algoritmos de Segmentação em Grafos. In:
XXIV Seminário de Iniciação Científica, 2012, São Luís - MA.

MOREIRA, A. S. ; JUNIOR, G. B. ; ROCHA, S. V. ; SILVA, A. C. ; PAIVA, A. C. .
Uma Análise Comparativa de Métodos para Segmentação de Imagens Mamográficas. In:
III Congresso de Ensino, Pesquisa e Extensão, 2012, São Luís - MA.

*“O sofrimento é o intervalo entre duas
felicidades”*

Vinícius de Moraes

Sumário

Lista de Figuras	10
Lista de Tabelas	12
1 Introdução	13
1.1 <i>O Problema</i>	14
1.2 <i>Sistemas CAD/CADx</i>	15
1.3 <i>Objetivos</i>	16
1.3.1 <i>Objetivos Gerais</i>	16
1.3.2 <i>Objetivos Específicos</i>	16
1.4 <i>Organização do Trabalho</i>	17
2 Fundamentação Teórica	18
2.1 <i>Realce da Imagem</i>	18
2.2 <i>Segmentação Baseada em Grafo</i>	20
2.3 <i>Índices de Diversidade de Espécies</i>	23
2.3.1 <i>Índice de Simpson</i>	23
2.3.2 <i>Índice de Shannon</i>	24
2.3.3 <i>Índice de McIntosh</i>	24
2.4 <i>Matriz de Co-Ocorrência e Run-Length</i>	25
2.5 <i>Máquinas de Vetores de Suporte</i>	27
2.6 <i>Avaliação dos Resultados</i>	30
3 Metodologia	32
3.1 <i>Melhoramento da Imagem</i>	33

3.2	<i>Segmentação Baseada em Grafo</i>	36
3.3	<i>Redução de Falsos Positivos</i>	38
4	Testes e Resultados	43
5	Conclusão	49
	Referências Bibliográficas	51

Lista de Figuras

1.1	Representação das etapas do processamento de imagem.	15
2.1	Imagem extraída de (WIRTH; FRASCHINI; LYON, 2004). Demonstrativo do elemento estruturante não-plano “ball-shaped”. (a) Vista superior do elemento estruturante, (b) Mesmo elemento estruturante de (a) porém com seu aspecto tridimensional visível.	19
2.2	Imagem representando segmentação de baixa qualidade. A ponderação das arestas é inversamente proporcional à distância entre elas. Portanto, uma abordagem de segmentação baseada apenas no corte mínimo nos sugere o corte mínimo 1 e 2, enquanto que o corte desejável é representado pela linha tracejada. Imagem adaptada de (MALIK et al., 2001)	21
2.3	Imagem extraída de (MALIK et al., 2001). À esquerda, imagem original com bounding box demonstrando a região a ser analisada. Pixels P_1 , P_2 e P_3 com intensidades similares, porém uma borda separa P_1 e P_3 , mas não P_2 o que sugere que P_1 e P_2 pertencem à um mesmo objeto, enquanto P_3 pertence a outro.	22
2.4	Duas regiões com o mesmo histograma, mas disposição espacial dos elementos diferentes.	25
2.5	Codificação de textura em matriz de co-ocorrência. (a) Imagem original. (b) Matriz de co-ocorrência para $\Theta = 0^\circ$ e $d=1$	26
2.6	Codificação de textura em Matriz run-length. (a) Imagem original. (b) Matriz run-length para $\Theta = 0^\circ$	26
2.7	Possíveis ângulos utilizados na geração da matriz de co-ocorrência	27
2.8	Geração de um classificador através do aprendizado supervisionado	28
2.9	Vetores de suporte em destaque com círculos.	29
3.1	Etapas da metodologia desenvolvida.	32

3.2	Demonstrativo da remoção do fundo da imagem mamográfica. (a) Imagem original mdb012 do MIAS (SUCKLING et al., 1994), (b) Imagem após a remoção do fundo.	34
3.3	Imagem mdb058 (SUCKLING et al., 1994) com o músculo peitoral extraído após a remoção do fundo mamográfico.	34
3.4	Comparativo dos resultados obtidos com técnicas de realce da imagem mdb058 (SUCKLING et al., 1994). (a) Imagem sem nenhum realce, (b) Realce no domínio da DWT, (c) Non-Linear Unsharp Masking, (d) Realce morfológico com elemento estruturante não-plano, (e) Combinação CLAHE e Mean-Shift.	36
3.5	Resultados da segmentação com cortes normalizados na imagem mdb058 (SUCKLING et al., 1994). (a) Imagem original com marcação do especialista em vermelho, (b) Imagem segmentada em 35 regiões, (c) Imagem segmentada em 45 regiões, (d) Imagem segmentada em 55 regiões.	37
3.6	Resultado da técnica proposta por Felzenszwalb e Huttenlocher (2004) na imagem mdb058 (SUCKLING et al., 1994). (a) Imagem original com marcação do especialista em vermelho, (b) Resultado da técnica de segmentação proposta por Felzenszwalb e Huttenlocher (2004) com sigma igual à zero, k igual à 350 e min igual à 150.	38
3.7	Procedimentos realizados na etapa de redução de falsos positivos	39
3.8	Comparativo do resultado da fase de redução de falsos positivos. (a) Imagem mamográfica segmentada, (b) Um único grupo restante após a fase de redução de falsos positivos. Cada grupo gerado pela segmentação está representado por uma cor diferente na imagem e a demarcação em vermelho em (b) representa a região que o especialista destacou como suspeita	40
3.9	Região extraída com formato de cruz.	40
3.10	Região extraída com o formato da menor elipse envolvente.	41
3.11	Região extraída com folga (GAP).	41
3.12	Extração da região igualmente como ela foi segmentada.	41
3.13	Região extraída equivalente ao menor quadrado envolvente da região. . . .	41

Lista de Tabelas

4.1	Limiares utilizados para o descarte de regiões com base a média de intensidade e desvio padrão	43
4.2	Comparativo das segmentações produzidas para imagens do grupo adiposa	44
4.3	Comparativo das segmentações produzidas para imagens do grupo levemente adiposas	44
4.4	Comparativo das segmentações produzidas para imagens do grupo das densas	44
4.5	Cinco melhores resultados da classificação com base nos melhores valores de sensibilidade. Os valores demonstrados de VP, FP, VN E FN são relativos aos valores médios das cinco execuções realizadas sob mesma configuração da MVS.	46
4.6	Resultados obtidos com a mesma descrição, porém com mudança na porcentagem das amostras utilizadas para o treinamento da MVS.	47
4.7	Resultados obtidos com variação na forma de extrair a região da imagem .	48

1 Introdução

O termo câncer refere-se a um grande conjunto de doenças que afetam qualquer parte do corpo e tem como principal característica o crescimento anormal da célula que pode invadir outros órgãos. Este processo é conhecido como metástase e é a principal causa de morte por câncer (WHO, 2012).

A pesquisa feita pela World Health Organization (WHO) revela que o câncer em 2008 levou 7.6 milhões de pessoas ao óbito no mundo todo, equivalente a 13% de todas as mortes ocorridas naquele ano, sendo que os principais tipos de câncer registrados naquele ano são o de pulmão, estômago, fígado, colo e o de mama. Cerca de 30% das mortes por câncer são devidos aos cinco principais riscos comportamentais e alimentares: índice de massa corporal elevado; baixa ingestão de frutas, legumes e verduras; a falta de atividade física; tabagismo e uso de álcool (WHO, 2012).

No Brasil, estimativas apontam que 518.510 novos casos de câncer serão registrados no ano de 2012, onde 257.870 casos surgirão no sexo masculino e 260.640 no grupo feminino. Para o grupo feminino, o câncer de mama será o predominante, representando 52.680 novos casos, 27,9% de todos os novos casos de câncer no grupo feminino, segundo pesquisa divulgada pelo Instituto Nacional do Câncer (INCA) (INCA, 2012). A pesquisa revela ainda que o estado do Maranhão encerrará o ano de 2012 com 460 novos casos de câncer de mama, sendo que 190 casos surgirão na capital, São Luís, representando uma taxa bruta de 35,65 de incidência para 100 mil habitantes.

A melhor forma de combater o câncer de mama ainda reside na detecção precoce do mesmo, daí a importância da realização da mamografia de rastreamento, principalmente para as mulheres acima dos quarenta anos de idade, dentro do grupo de risco (AZEVEDO; PEIXOTO, 1993). Quando o câncer é detectado em estágios iniciais é possível realizar um tratamento menos agressivo e com maiores chances de cura ao paciente. A fim de promover a saúde pública de qualidade, o governo brasileiro criou a Lei 11.664/2008 (DOU, 2008), em vigor desde abril de 2009, que dispõe da efetivação de ações de saúde que asseguram a prevenção, a detecção e o tratamento dos cânceres do colo uterino e de mama inseridas no âmbito do Sistema Único de Saúde (SUS). Além

disso, diversas campanhas foram feitas a fim de conscientizar as mulheres, principalmente as que estão dentro do grupo de risco, da importância da mamografia.

Tais campanhas levaram ao recorde de 2.139.238 de mamografias realizadas em 2012 pelo SUS, representando um aumento de 41% no número de mamografias entre as mulheres na faixa prioritária (50 a 69 anos) se comparado ao mesmo período de 2010 (SUS, 2012). No Maranhão, o SUS realizou 28.984 mamografias no ano de 2012, representando, até então, um aumento de 10% se comparado com o mesmo período de 2011.

1.1 *O Problema*

Apesar de a mamografia ser grande aliada na detecção precoce do câncer de mama, vários fatores têm interferido na análise da mesma, resultando em falhas nos laudos emitidos por radiologistas que variam entre 10% a 30% (BIRD; WALLACE; YANKASKAS, 1992). Em entrevista recente, o secretário de Atenção à Saúde, Helvécio Magalhães, do Ministério da Saúde, afirmou que algumas cidades do Brasil chegam a ter até 50% de dificuldade de leitura e de diagnóstico fazendo uso da mamografia.

Tais ocorrências levaram o Ministério da Saúde a instituir o Programa Nacional de Qualidade em Mamografia (PNQM) com o objetivo de minimizar os riscos associados ao uso dos raios-X, assim como garantir a qualidade no diagnóstico. Diversos fatores contribuem para uma possível falha na detecção ou caracterização do câncer de mama, em geral podemos citar o uso de técnicas radiográficas inadequadas, lesão com características sutis ou incomuns, erro de interpretação e, principalmente, a restrição de resolução e contraste da imagem da mamografia que resultam na diminuição da visualização de tumores de mama e microcalcificações em pacientes com tecido fibroglandular denso¹ (HUYNH; JAROLIMEK; DAYE, 1998).

¹Tecido presente na mama, encontrado em maior concentração em mulheres com idades mais novas. Gradativamente, o tecido fibroglandular vai sendo substituído por tecido adiposo, processo este conhecido por lipossustituição

1.2 Sistemas CAD/CADx

Diante deste cenário técnicas de processamento de imagens e visão computacional têm sido adotadas para dar suporte aos especialistas da área a fim de minimizar os erros envolvidos no diagnóstico médico em busca de lesões no parênquima mamário através do uso de imagens médicas da mama. Tais técnicas têm servido como suporte para a construção de sistemas de detecção auxiliado por computador, *Computer-Aided Detection (CAD)*, e sistemas de diagnóstico auxiliado por computador, *Computer-Aided Diagnosis (CADx)*.

Esses sistemas têm sido de grande importância para diminuição dos erros dos diagnósticos, atuando como uma segunda opinião médica onde o especialista corrobora ou não com o laudo dado por estes sistemas. Pesquisas demonstram que os casos de acertos no laudo de câncer de mama poderiam ser aumentados de 5% a 15% caso sejam utilizados sistemas CAD (FREER; ULISSEY, 2001).

De forma geral, as metodologias utilizadas por sistemas CAD/CADx baseadas em visão computacional e processamento de imagens seguem o fluxo representado pela Figura 1.1. O processamento digital de imagens envolve processos cujas entradas e saídas são imagens e, além disso, envolve processos de extração de atributos de imagens até - e inclusive - o reconhecimento de objetos individuais (GONZALEZ; WOODS, 2007).

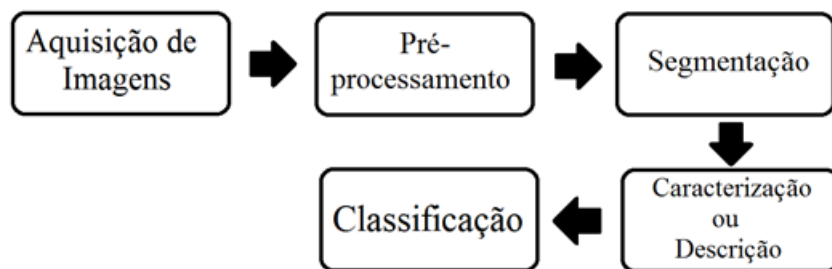


Figura 1.1: Representação das etapas do processamento de imagem.

Vários estudos têm sido propostos a fim de auxiliar a detecção precoce do câncer de mama. Guliato, Barcelos e Dias (2008) utilizam um filtro de suavização anisotrópica via Equações Diferenciais Parciais na fase de pré-processamento para a detecção de regiões suspeitas em mamografias. Já Zhang et al. (2011) propõem um algoritmo automático para detecção de tumores em imagens mamográficas através do uso da lógica fuzzy.

Jo et al. (2013) extrai o ponto médio da massa com a utilização do AHE (Adaptative Histogram Equalization) e em seguida é aplicado um desfoque a fim de estabilizar a região da massa. Por fim, é utilizado o MVS (Máquinas de Vetores de Suporte) para a análise das propriedades da textura. Gopal e Kanaga (2013) produziram um trabalho onde é feito um estudo comparativo de diversas técnicas de realce de imagens aplicadas às imagens mamográficas.

1.3 *Objetivos*

1.3.1 *Objetivos Gerais*

Este trabalho propõe uma nova metodologia capaz de dar suporte ao diagnóstico médico na tarefa de detecção de regiões suspeitas na mama através do uso de imagens médicas da mesma. Para tal, a metodologia proposta visa minimizar o número de falsos positivos, tentando ao mesmo tempo não diminuir a taxa de acerto de massas da metodologia.

1.3.2 *Objetivos Específicos*

Inicialmente, são adotadas técnicas de realce de imagem visando melhorar a qualidade da imagem a ser trabalhada, além de algoritmos para extração de músculo peitoral e do fundo da imagem. A fim de extrair as regiões de interesse, é utilizado algoritmo de segmentação baseado em grafo através de cortes normalizados. A segmentação da imagem da mama produz diversas regiões que não correspondem a região de massa, sendo que estas regiões influenciam diretamente no número de falsos positivos produzidos pela metodologia. Por isso, é realizada uma verificação da média e do desvio padrão de cada região a fim de descartar as regiões produzidas na segmentação que não possuem características que são comumente encontradas em regiões de massa, minimizando assim o número de regiões investigadas e reduzindo a taxa de falso positivo da metodologia. Por fim, é feita um estudo da influência das regiões vizinhas à regiões de massa através da extração das regiões em diversos formatos geométricos. Após extraídas, as regiões são caracterizadas através de Índices de Biodiversidade combinadas com matriz de co-ocorrência e matriz run-length em vários níveis de quantização, distância e ângulo. As

regiões após serem caracterizadas são classificadas com o auxílio das Máquinas de Vetores de Suporte.

1.4 *Organização do Trabalho*

Nas próximas seções serão apresentados os conceitos teóricos acerca das técnicas empregadas na construção da metodologia proposta. Primeiramente são apresentados os fundamentos teóricos relacionados às técnicas utilizadas neste trabalho, tais como a técnica de Realce Morfológico com Elementos Estruturantes não-planos, o algoritmo de segmentação baseado em grafo através de corte normalizado para a extração de regiões de interesse da imagem. Posteriormente, são descritos os índices de diversidade de espécie com matriz de co-ocorrência e run-length para caracterização das regiões e, por fim, é feito um detalhamento sobre as máquinas de vetores de suporte para a classificações das regiões analisadas. Na segunda parte são apresentadas as etapas seguidas na metodologia utilizando os conceitos abordados previamente. Por fim, são exibidos os resultados obtidos nos testes realizados e uma discussão final sobre o assunto.

2 Fundamentação Teórica

Esta seção descreve os principais conceitos teóricos empregados na construção da metodologia proposta neste trabalho.

2.1 *Realce da Imagem*

Grande parte das mamografias realizadas apresenta baixa qualidade na imagem produzida, o que torna o processo de detecção de neoplasias mais difícil. Portanto, é importante para o sucesso da metodologia que todas as estruturas do parênquima mamário apresentem um bom contraste em relação aos outros elementos.

Diante dessa necessidade de melhorar a imagem a ser trabalhada, o Realce Morfológico com Elementos Estruturantes não-planos (WIRTH; FRASCHINI; LYON, 2004) apresentou resultados satisfatórios. Visto que as microcalcificações e regiões de massas se projetadas em um relevo 3D apresentam um comportamento geométrico semelhante a domos, o realce dessas estruturas podem ser alcançadas através do uso de elementos estruturantes em três dimensões.

Uma operação morfológica, em processamento de imagem, consiste basicamente na comparação de uma imagem com uma outra menor que apresenta uma geometria conhecida e desejável, esta imagem de referência é denominada elemento estruturante. Tradicionalmente, análises morfológicas têm sido utilizadas através de elementos estruturantes planos. Elementos estruturantes não-planos consistem em elementos estruturantes em três dimensões com o objetivo de capturar regiões que apresentem forma geométrica igual quando estas são plotadas em uma superfície tridimensional relativo a localização espacial e à intensidade dos pixels da mesma. Portanto, levando em consideração o aspecto geométrico das regiões de massa e calcificações, é perceptível a relevância da utilização do elemento estruturante em formato de bola (“ball-shaped”), conforme a Figura 2.1.

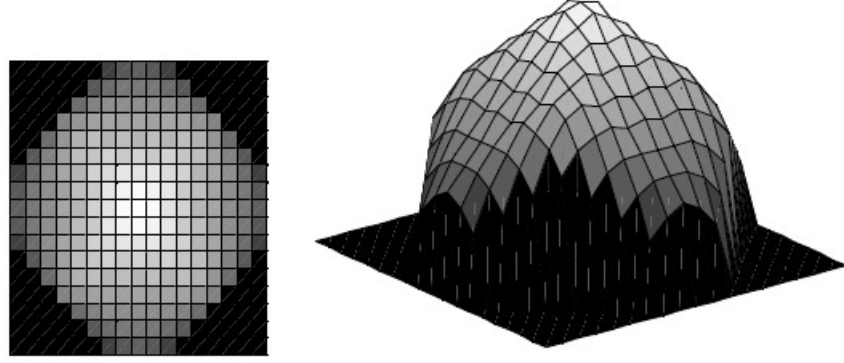


Figura 2.1: Imagem extraída de (WIRTH; FRASCHINI; LYON, 2004). Demonstrativo do elemento estruturante não-plano “ball-shaped”. (a) Vista superior do elemento estruturante, (b) Mesmo elemento estruturante de (a) porém com seu aspecto tridimensional visível.

O Realce Morfológico é derivado da técnica top-hat (MEYER, 1979). A técnica top-hat consiste em uma operação que preserva as características e detalhes da imagem que se adaptam ao elemento estruturante e remove os que não se adaptam. O resultado é obtido através da obtenção tanto do top-hat de abertura quanto do top-hat de fechamento. O top-hat de abertura, γ_{TH} , corresponde a diferença entre a imagem original, I_O , e sua abertura em escala de cinza, γ_B , usando um elemento estruturante.

$$\gamma_{TH} = I_O - \gamma_B \quad (2.1)$$

Já o top-hat de fechamento, ϕ_{TH} , é obtido através da diferença entre o fechamento em escala de cinza, ϕ_B , usando o elemento estruturante B e sua imagem original I_O .

$$\phi_{TH} = \phi_B - I_O \quad (2.2)$$

A adição do top-hat de abertura à imagem original proporciona uma acentuação das estruturas com intensidades altas, enquanto que a subtração do top-hat de fechamento resulta em uma acentuação das regiões com baixa intensidade. Logo, a técnica de Realce Morfológico com Elementos Estruturantes não planos pode ser definida como:

$$K = I_O + \gamma_{TH} - \phi_{TH} \quad (2.3)$$

2.2 Segmentação Baseada em Grafo

A segmentação de uma imagem visa delimitar regiões de interesses presentes na imagem. Vários algoritmos e técnicas de segmentação têm sido propostos, cada um apresentando um comportamento e resultado peculiar. Em geral, as técnicas mais utilizadas por algoritmos de segmentação baseiam-se na análise de descontinuidade, presença de bordas e disposição da intensidade dos pixels na imagem.

Uma técnica que tem sido amplamente utilizada para segmentar imagens é o uso de clusterizadores através do uso de grafos. Dada uma imagem I , pode-se construir um grafo $G = (V, E, W)$, com os pixels de I modelados como nós do grafo (V), e pixels com distância $\leq Gr$ são conectados por uma aresta do grafo (E). Um valor de peso $W(i, j)$ mensura a probabilidade dos pixels i e j pertencerem a mesma região. A partição deste grafo provê a segmentação de regiões da imagem.

O processo de particionamento de um grafo corresponde ao corte do mesmo originando assim subgrafos. O corte realizado no grafo é associado a um valor algébrico que representa o grau de semelhança entre as componentes disjuntas geradas. Este valor pode ser calculado através da Equação 2.4.

$$Corte(A, B) = \sum_{i \in A, j \in B} p(i, j) \quad (2.4)$$

onde $p(i, j)$ corresponde ao peso da aresta que conectava os dois subgrafos gerados.

De modo geral, as técnicas de segmentação baseada em grafo tentam minimizar o custo do corte. Porém tal prática pode levar à baixa qualidade de segmentação, tendo em vista que o cálculo do custo não leva em consideração o número de vértices presentes em cada um subgrafo, podendo acontecer, assim, segmentações triviais como mostrado na Figura 2.2.

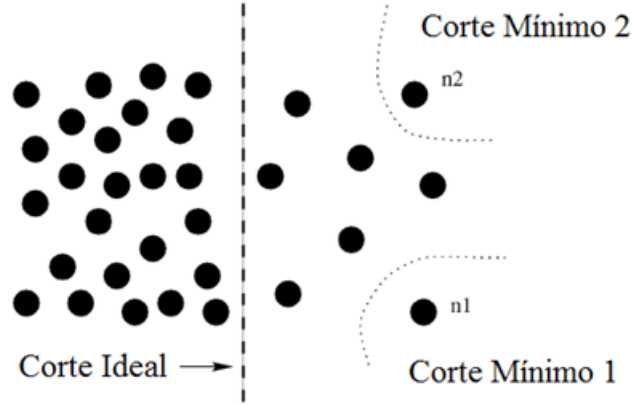


Figura 2.2: Imagem representando segmentação de baixa qualidade. A ponderação das arestas é inversamente proporcional à distância entre elas. Portanto, uma abordagem de segmentação baseada apenas no corte mínimo nos sugere o corte mínimo 1 e 2, enquanto que o corte desejável é representado pela linha tracejada. Imagem adaptada de (MALIK et al., 2001)

Como pode ser observado na Figura 2.2, pontos isolados têm preferência no corte devido a minimização no valor produzido por este corte. Visando resolver este problema, em (MALIK et al., 2001) é proposto um novo cálculo no custo do corte que gera subgrafos com quantidade de nós mais balanceados. Tal cálculo é obtido pela Equação 2.5.

$$NCUT(A, B) = \frac{CUT(A, B)}{Volume(A) \times Volume(B)} \quad (2.5)$$

Esta função pode ser reescrita usando uma função indicadora de grupo binário $X_l \in \{0, 1\}^N$, com $X_l(i) = 1$ se o pixel i pertence ao segmento l .

Seja $X = [X_1, X_2]$ e D uma matriz diagonal onde $D(i, j) = \sum W(i, j)$. O critério utilizado para a quantidade da segmentação é definido como:

$$maximize \in (X) = \frac{1}{2} \sum_{l=1}^2 \frac{X_l^T W X_l}{X_l^T D X_l} \quad (2.6)$$

Uma função de custo k -way generalizada pode ser definida como $X = [X_1, \dots, X_K]$. Encontrar a partição NCut ótima do grafo é uma tarefa NP-complexo. A técnica de partição de um grafo de espectro permite solucionar este problema usando uma solução em um espaço contínuo pela computação do autovetor K correspondente ao

maior autovalor K em:

$$WV = \lambda DV \quad (2.7)$$

A qualidade global da segmentação depende da afinidade par a par dos pixels no grafo, quesito que é levado em conta na ponderação do grafo. Duas simples, mas eficientes, medidas de afinidade são: intensidade e contorno.

Para a intensidade, é levado em conta o fato de que pixels que estão próximos e possuem intensidades similares, provavelmente pertence ao mesmo grupo. Portanto, a ponderação do grafo pode ser seguida através da Equação 2.8.

$$W_i(i, j) = e^{-\frac{\|X_i - X_j\|^2}{\sigma_x} - \frac{\|I_i - I_j\|^2}{\sigma_I}} \quad (2.8)$$

onde X e I denotam a localização e intensidade do pixel, respectivamente.

Conectar pixels pela intensidade é útil para juntar partes disjuntas do objeto. Porém, devido à heterogeneidade da textura, levar em conta somente a intensidade não garante boas segmentações.

Outra característica de uma imagem que pode ser levada em conta na ponderação do grafo é a presença de bordas, pois, de modo geral, as bordas da imagem constituem uma provável fronteira para os objetos presentes na mesma. Tal quesito é particularmente útil quando o fundo da imagem possui valores de intensidades semelhantes ao corpo do objeto, como mostrado na Figura 2.3.




Figura 2.3: Imagem extraída de (MALIK et al., 2001). À esquerda, imagem original com bounding box demonstrando a região a ser analisada. Pixels P_1 , P_2 e P_3 com intensidades similares, porém uma borda separa P_1 e P_3 , mas não P_2 o que sugere que P_1 e P_2 pertencem à um mesmo objeto, enquanto P_3 pertence a outro.

A afinidade entre dois pixels pode ser mensurada através da magnitude das arestas da imagem entre ambos, conforme a Equação 2.9.

$$W_c(i, j) = e^{-\frac{\max_{x \in \text{line}(i, j)} \|Edge(x)\|^2}{\sigma_c}} \quad (2.9)$$

onde $\text{line}(i, j)$ é uma linha reta ligando os dois pixels i e j ; e $Edge(x)$ é o peso da aresta na localização x .

As duas abordagens de codificação das arestas do grafo, através da intensidade e dos contornos interferentes, podem ser combinadas em uma única equação, como segue:

$$W_{mixed}(i, j) = \sqrt{W_i(i, j) \times W_c(i, j)} + \alpha W_c(i, j) \quad (2.10)$$

2.3 Índices de Diversidade de Espécies

Os índices de diversidade de espécies são índices que são utilizados em investigações demográficas e de biodiversidade. Tais índices mensuram o quão heterogêneo é a amostra em análise. Estes índices podem ser aplicados ao processamento de imagem fazendo uma analogia dos elementos da imagem com elementos da natureza. Cada Region of Interest (ROI) da imagem passa a ser considerada uma biosistema em estudo e cada elemento dessa amostra, neste caso os pixels, pode ser considerado uma espécie.

Os índices de diversidade são utilizados nesse trabalho para a extração de textura de regiões da mamografia. São estudados os seguintes índices:

2.3.1 Índice de Simpson

Índice de Simpson (SIMPSON, 1949) é um dos parâmetros que permitem medir a riqueza de organismos. Para tanto, é utilizado o número de espécies em seu habitat e abundância relativa de cada espécie. O índice de Simpson representa a probabilidade de que dois indivíduos dentro de um mesmo habitat sejam escolhidos aleatoriamente e ambos pertençam à mesma espécie. O índice é dado pela seguinte função:

$$D = \frac{\sum_{i=1}^S n_i(n_i - 1)}{N(N - 1)} \quad (2.11)$$

onde:

- **D** é o índice de Simpson;
- **S** é o número de espécies;
- **N** é o número total de indivíduos;
- **n** é o número de indivíduos por espécie.

2.3.2 Índice de Shannon

O índice de Shannon, ou índice Shannon-Weaver ou índice do Shannon-Wiener (SHANNON, 2001) é um índice de diversidade usado para mensurar a entropia dos dados. Tal índice pode ser calculado pela seguinte fórmula:

$$H' = - \sum_{i=1}^S p_i \ln p_i \quad (2.12)$$

onde:

- **H'** é o índice de Shannon;
- **S** é o número de espécies;
- **N** é o número total de indivíduos;
- P_i é abundância relativa de cada espécie, calculada pela proporção dos indivíduos de uma espécie pelo número total dos indivíduos na comunidade.

2.3.3 Índice de McIntosh

O índice de McIntosh (MCINTOSH, 1967) é outro índice de diversidade ecológica. Seu valor varia entre 0 e 1, onde quanto mais próximo do valor 1, significa que organismos encontram-se na comunidade distribuídos de forma mais homogênea (MCINTOSH, 1967). Tal índice pode ser calculado pela seguinte expressão:

$$D = \frac{N - U}{N - \sqrt{N}} \quad (2.13)$$

onde:

- D é o índice de McIntosh;
- N é o número total de indivíduos da amostra;
- U é calculado por:

$$U = \sqrt{\sum N_i^2} \quad (2.14)$$

onde:

- N_i é o número de indivíduos pertencentes a i -ésima espécie.

2.4 *Matriz de Co-Ocorrência e Run-Length*

Durante a descrição da região de interesse, é importante que além da distribuição intensidade de cinza, também seja levado em consideração a disposição espacial de cada elemento, permitindo uma descrição mais precisa da região.

Portanto, o uso de um simples histograma de uma dimensão não possibilita uma descrição apropriada da região, visto que uma região em preto em branco disposta da forma de um tabuleiro de xadrez seria descrita da mesma forma que uma região do mesmo tamanho e com metade preta e a outra metade branca. Neste caso, uma melhor descrição da região é obtida com o uso da matriz de co-ocorrência.



Figura 2.4: Duas regiões com o mesmo histograma, mas disposição espacial dos elementos diferentes.

A matriz de co-ocorrência (HARALICK; SHANMUGAM; DINSTEIN, 1973) de uma imagem I quantizada em N níveis de cinzas para dado um ângulo Θ e uma distância d

é representada por uma matriz $M_{N \times N}$ onde $M(p, q)$ indica a quantidade de ocorrências onde um pixel de intensidade q é vizinho de um pixel de intensidade p à uma distância d e formando um ângulo Θ com o mesmo.




Figura 2.5: Codificação de textura em matriz de co-ocorrência. (a) Imagem original. (b) Matriz de co-ocorrência para $\Theta = 0^\circ$ e $d=1$.

Já a matriz Run-Length (GALLOWAY, 1975) codifica a textura levando em consideração a quantidade de vezes que um mesmo nível de cinza i aparece em uma sequência j a uma determinada direção Θ .




Figura 2.6: Codificação de textura em Matriz run-length. (a) Imagem original. (b) Matriz run-length para $\Theta = 0^\circ$.

Em geral as técnicas que usam a matriz de co-ocorrência e matriz run-length utilizam um dos quatro ângulos: 0° , 45° , 90° e 135° , conforme mostrados na Figura 2.7.




Figura 2.7: Possíveis ângulos utilizados na geração da matriz de co-ocorrência

2.5 Máquinas de Vetores de Suporte

As Máquinas de Vetores de Suporte, Máquinas de Vetores de Suporte (MVS), (CORTES; VAPNIK, 1995) constituem uma técnica de aprendizado de máquina baseada pela teoria do aprendizado estatístico, desenvolvida por Vapnik com os estudos iniciados em (VAPNIK; CHERVONENKIS, 1971). Tal teoria define uma série de princípios que permitem obter classificadores com uma boa generalização, possibilitando que novos dados do mesmo domínio que o aprendizado ocorreu possam reconhecidos.

O processo de aprendizado das Máquinas de Vetores de Suporte é realizado durante o treinamento da mesma através da figura de um professor externo, o qual apresenta o conhecimento do ambiente por conjuntos de exemplos na forma: entrada e saída desejada ou rótulos (HAIKIN, 1998), processo característico da aprendizagem supervisionada. A partir do processo de aprendizagem, deve-se produzir um classificador que seja capaz de prever o rótulo de novos dados.

A Figura 2.8 representa de forma simplificada os conceitos empregados no processo de geração de um classificador através do aprendizado supervisionado.




Figura 2.8: Geração de um classificador através do aprendizado supervisionado

Em casos em que o conjunto de amostras é composto por duas classes separáveis, um classificador MVS é capaz de encontrar um hiperplano baseado em um conjunto de pontos denominados “vetores de suporte”, o qual maximiza a margem de separação entre as classes. A equação de um hiperplano é apresentada na Equação 2.15, em que $w \cdot x$ é o produto escalar entre os vetores w e x , onde w é o vetor normal ao hiperplano descrito e corresponde à distância do hiperplano em relação à origem.

$$f(x) = w \cdot x + b = 0 \quad (2.15)$$

A fim de encontrar os valores ótimos de w e x é necessário que tais valores maximizem a margem existente entre o hiperplano e os vetores de suporte. Tais valores são encontrados com a minimização da seguinte equação:

$$\Phi(w) = \frac{w^2}{2} \quad (2.16)$$

com a seguinte restrição:

$$y_i = (w \cdot x_i + b) \geq 1 \quad (2.17)$$

Com a introdução de variáveis de folgas, é possível encontrar um hiperplano que minimize a ocorrência de erros de classificação nos casos em que uma perfeita separação entre as duas classes não for possível. O problema de otimização passa a ser então a minimização da seguinte Equação 2.18. C é um parâmetro de treinamento que estabelece

um equilíbrio entre a complexidade do modelo e o erro de treinamento e deve ser selecionado pelo usuário.

$$\Phi(w, \xi) = \frac{w^2}{2} + C \sum_{i=1}^N \xi_i \quad (2.18)$$

para:

$$y_i((w \cdot x_i + b) + \xi_i) \geq 1 \quad (2.19)$$

Através da teoria dos multiplicadores de Lagrange, chega-se a Equação 2.20. O objetivo então passa a ser encontrar os multiplicadores de Lagrange α_i ótimos que satisfaçam a Equação 2.21 (CHAVES, 2006).

$$w(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j (x_i x_j) \quad (2.20)$$

$$\sum_{i=1}^N \alpha_i y_i = 0, \quad 0 \leq \alpha_i \leq C \quad (2.21)$$

Os vetores de suporte satisfazem a restrição 2.19 com resultado igual à uma unidade e com $\alpha \neq 0$. A Figura 2.9 destaca os pontos que representam os vetores de suporte. Os pontos além da margem não influenciam decisivamente na determinação do hiperplano, enquanto que os vetores de suporte, por terem pesos não nulos, são decisivos.




Figura 2.9: Vetores de suporte em destaque com círculos.

As MVS's podem classificar amostras que não são linearmente separáveis através de uma transformação não-linear que transforma o espaço de entrada (dados) para um novo espaço (espaço de características). Se a dimensão desse novo espaço

for suficientemente grande, é possível fazer uma separação linear da amostra. Logo, o hiperplano 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, 2001). A função K pode realizar o mapeamento das amostras para um espaço de dimensão muito elevada sem aumentar a complexidade dos cálculos. A Equação 2.22 mostra o resultado da Equação 2.20 com a utilização de um núcleo.

$$w(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (2.22)$$

Uma importante família de funções de núcleo é a função de base radial, definida por:

$$K(w_i, w_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (2.23)$$

2.6 Avaliação dos Resultados

Três medidas importantes para avaliar a metodologia são: a sensibilidade (*Sens*), a especificidade (*Esp*) e a acurácia (*Acc*).

A sensibilidade, **Sens**, é a medida de acerto da metodologia levando em conta somente as regiões que apresentam neoplasia e é calculada pela Equação 2.24.

$$Sens = \frac{VP}{VP + FN} \quad (2.24)$$

onde:

- **Sens** é a sensibilidade;
- **VP** é a quantidade de regiões que foram indicadas pela metodologia como uma região que apresenta neoplasia e de fato é uma região com neoplasia;
- **FN** é a quantidade de regiões que foram indicadas pela metodologia como uma região que não apresenta neoplasia, mas, na verdade, esta região apresenta neoplasia.

A especificidade, **Esp**, representa a capacidade que a metodologia tem de diagnosticar regiões que não apresentam neoplasia e é calculada pela Equação 2.25.

$$Esp = \frac{VN}{VN + FP} \quad (2.25)$$

onde:

- **Esp** é a especificidade;
- **VN** é a quantidade de regiões que foram indicadas pela metodologia como uma região que não apresenta neoplasia e de fato é uma região sem neoplasia;
- **FP** é a quantidade de regiões que foram indicadas pela metodologia como uma região que apresenta neoplasia, mas, na verdade, esta região não apresenta neoplasia.

Já a acurácia, **Acc**, representa a taxa de acerto global da metodologia e é calculada pela Equação 2.26.

$$Acc = \frac{VN + VP}{VP + FP + VN + FN} \quad (2.26)$$

onde:

- **Acc** é a acurácia;
- **VP** é a quantidade de regiões que foram indicadas pela metodologia como uma região que apresenta neoplasia e de fato é uma região com neoplasia;
- **FN** é a quantidade de regiões que foram indicadas pela metodologia como uma região que não apresenta neoplasia, mas, na verdade, esta região apresenta neoplasia.
- **VN** é a quantidade de regiões que foram indicadas pela metodologia como uma região que não apresenta neoplasia e de fato é uma região sem neoplasia;
- **FP** é a quantidade de regiões que foram indicadas pela metodologia como uma região que apresenta neoplasia, mas, na verdade, esta região não apresenta neoplasia.

3 Metodologia

Esta seção descreve as atividades realizadas na construção da metodologia proposta, apresentando cada técnica envolvida neste processo, além de exibir a análise dos mesmos, explicitando assim os motivos que levaram certas técnicas a serem escolhidas em detrimento de outras.

A metodologia descrita visa a construção de um sistema CAD/CADx para auxiliar a tarefa de detecção de massas em imagens de mamografias. As etapas envolvidas na metodologia propostas são representadas na Figura 3.1.

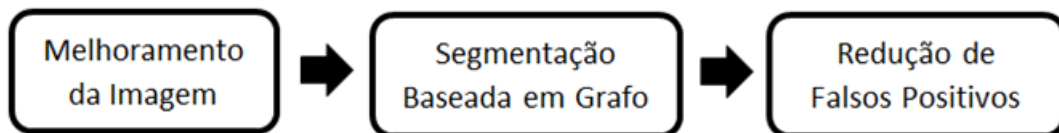


Figura 3.1: Etapas da metodologia desenvolvida.

A primeira etapa, Melhoramento da Imagem, visa corrigir possíveis imperfeições oriundas no processo de aquisição da imagem e realizar manipulações iniciais de modo que a imagem a ser trabalhada em etapas futuras apresente características desejáveis.

A segmentação de imagens corresponde a extrair regiões de interesses na imagem. Este trabalho faz o uso da segmentação baseada em grafo através de corte normalizado na imagem médica da mama. O objetivo é obter regiões suspeitas que serão avaliadas nas etapas seguintes.

Por fim, a etapa de Redução de Falsos Positivos proporciona uma diminuição na quantidade de regiões falsos positivas geradas pela metodologia. Para tal, as regiões geradas na etapa anterior são analisadas individualmente e estas são descartadas caso não apresentem características comumente encontradas em regiões anômalas. As características levadas em consideração na análise vão desde a média de intensidade e desvio padrão a descrição das mesmas através da combinação de índices de diversidade de espécies com as matrizes de co-ocorrência e run-length. Por fim, as bases geradas com essa descrição são classificadas através do uso de Máquinas de Vetores de Suporte.

Nas próximas seções serão apresentados detalhadamente como cada etapa foi

executada e os resultados obtidos em cada uma delas.

3.1 *Melhoramento da Imagem*

O processo de aquisição da imagem mamográfica nem sempre resulta em imagens de alta qualidade, normalmente em imagens de baixo contraste. Além disso, especificamente na mamografia, questões naturais e hormonais influenciam nas características adquiridas na imagem. Mulheres com idade mais avançada e que já tenham atingido a pós-menopausa apresentam uma predominância do tecido adiposo. Logo, a imagem mamográfica de uma paciente mais jovem apresenta menor contraste entre as estruturas internas devido a uma grande presença de tecido denso.

Tais características configuram-se um obstáculo tanto para o processo manual de detecção e diagnóstico de anomalias através de imagens médicas quanto para os sistemas computacionais de detecção e diagnóstico. Por este motivo, fez-se necessário suprimir os ruídos e realçar as estruturas internas da mama através de procedimentos aqui descritos.

De modo geral, o fundo da imagem mamográfica apresenta diversos elementos indesejáveis, tais como ruídos e a etiqueta de identificação do paciente. Portanto, é de grande importância a remoção desses elementos através da extração do fundo, eliminando assim a possibilidade de interferência desses elementos em etapas futuras da metodologia. Os fundos das imagens analisadas foram extraídos através da aplicação da função gaussiana de tamanho 12, seguida de uma binarização com limiar 128. A Figura 3.2 demonstra o resultado da extração do fundo da imagem




Figura 3.2: Demonstrativo da remoção do fundo da imagem mamográfica. (a) Imagem original mdb012 do MIAS (SUCKLING et al., 1994), (b) Imagem após a remoção do fundo.

Outro elemento que interfere negativamente nas análises futuras é a presença do músculo peitoral, pois esta região apresenta algumas características semelhantes a uma região de massa, como alta intensidade e baixo desvio padrão. A remoção do músculo peitoral foi executada através da técnica descrita em (SAMPAIO et al., 2011). Um exemplo do resultado obtido após a extração do músculo peitoral é apresentado na Figura 3.3.




Figura 3.3: Imagem mdb058 (SUCKLING et al., 1994) com o músculo peitoral extraído após a remoção do fundo mamográfico.

O realce das estruturas internas da mama e o aumento do contraste entre os elementos presentes no parênquima refletem diretamente em uma melhor segmentação dos elementos. Portanto, diversas técnicas de realce foram analisadas e estudadas, entre elas:

Realce no Domínio da DWT (VALE, 2006), *Nonlinear Unsharp Masking* (PANETTA et al., 2011), *Contrast Limited Adaptive Histogram Equalization* (ZUIDERVELD, 1994), *Mean-Shift* e, por fim, *Realce Morfológico com Elementos Estruturantes não-planos* (WIRTH; FRASCHINI; LYON, 2004).

O *Realce no Domínio da DWT* apesar de ser um algoritmo de fácil desenvolvimento, o resultado obtido com essa técnica pouco alterou o contraste das estruturas internas da mama, proporcionando apenas um aumento da intensidade global da imagem. A 2D-DWT foi implementada através de Daubechies 3 e com os parâmetros utilizados em (VALE, 2006).

A técnica *Nonlinear Unsharp Masking* conferiu um destaque significativo entre as estruturas internas da mama. Em (PANETTA et al., 2011) é utilizado a SDME (Second-Derivative-Like Measure of Enhancement) para estimar os melhores parâmetros para o realce. O SDME é aplicado a cada imagem de entrada, aumentando o tempo de execução da metodologia, e os resultados obtidos mesmo com a utilização do SDME nem sempre foram dentro do esperado.

Já o uso da técnica de realce morfológico com elementos estruturantes não-planos além de proporcionar as mesmas vantagens oferecidas pelo *Nonlinear Unsharp Masking*, o parâmetro de ajuste da técnica é mais intuitivo e corresponde unicamente ao tamanho do elemento estruturante. Além disso, diferentemente do *Nonlinear Unsharp Masking*, não foi necessário estimar o valor do parâmetro para cada imagem, sendo que a aplicação do mesmo elemento estruturante para todas as imagens apresentou um resultado satisfatório. O elemento estruturante utilizado nesta metodologia foi uma circunferência de raio 50.

Por fim, foi utilizado o Contrast Limited Adaptive Histogram Equalization (CLAHE) combinado com o Mean-Shift. O CLAHE foi utilizado com contraste igual a 0,018, resultando em uma imagem onde as estruturas de alta densidade são destacadas, preservando associações locais de intensidades. Em seguida, o resultado do CLAHE foi combinado com o MeanShift proporcionando um contraste das estruturas internas da mama e diminuindo os ruídos presentes nesta região.

Diante dos resultados obtidos, a técnica de realce através de operações morfológicas com elementos não-planos foi adotada para o desenvolvimento da metodologia, visto que esta técnica apresentou melhores resultados em comparação com as demais, além de ser

uma técnica de fácil ajuste e apresentar resultados coesos. A Figura 3.4 apresenta um comparativo entre os resultados obtidos com as técnicas descritas aqui.




Figura 3.4: Comparativo dos resultados obtidos com técnicas de realce da imagem mdb058 (SUCKLING et al., 1994). (a) Imagem sem nenhum realce, (b) Realce no domínio da DWT, (c) Non-Linear Unsharp Masking, (d) Realce morfológico com elemento estruturante não-plano, (e) Combinação CLAHE e Mean-Shift.

3.2 Segmentação Baseada em Grafo

Após a etapa de melhoramento da imagem, é realizada a segmentação, responsável por dividir uma imagem em múltiplas regiões ou segmentos de interesse. Duas técnicas de segmentação baseada em grafo foram testadas, entre elas a técnica proposta por (FELZENSZWALB; HUTTENLOCHER, 2004) e a segmentação em grafo através de cortes normalizados (SHI; MALIK, 2000).

Nos testes realizados com a técnica de segmentação baseada em grafo através de cortes normalizados, cada imagem foi segmentada três vezes, variando o número de segmentos em 35, 45 e 55. É apresentado na Figura 3.5 um exemplo do resultado obtido com o uso da técnica de segmentação que fora apresentada.

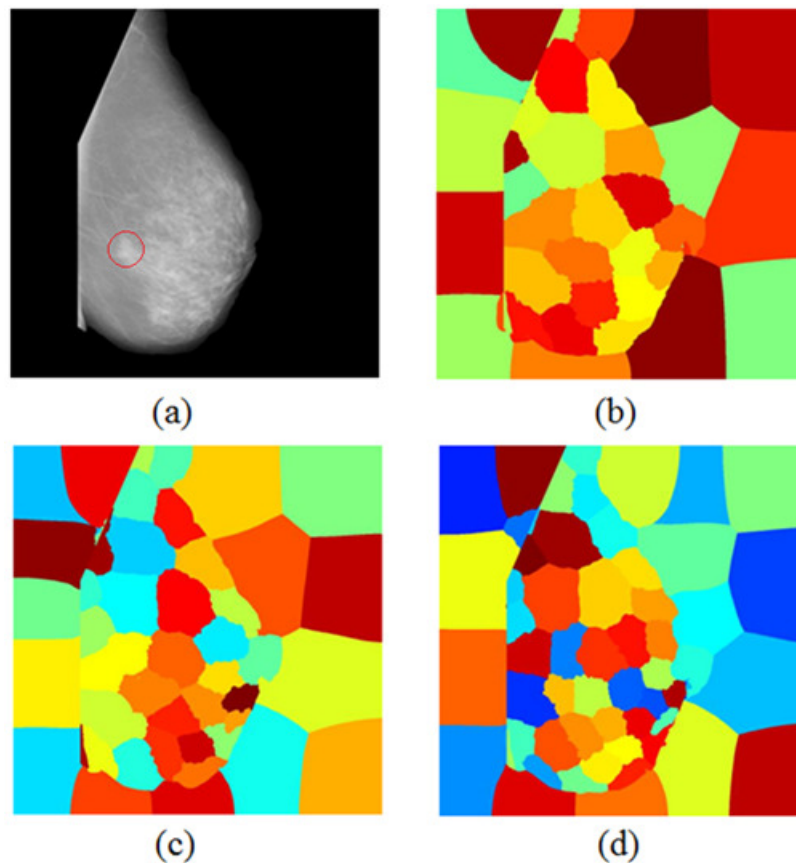


Figura 3.5: Resultados da segmentação com cortes normalizados na imagem mdb058 (SUCKLING et al., 1994). (a) Imagem original com marcação do especialista em vermelho, (b) Imagem segmentada em 35 regiões, (c) Imagem segmentada em 45 regiões, (d) Imagem segmentada em 55 regiões.

Já a técnica de segmentação também baseada em grafo proposta por Felzenszwalb e Huttenlocher (2004) foi utilizada com a seguinte configuração de parâmetros: nenhum desfoque foi aplicado às imagens (parâmetro σ), valor do k igual a 350 e \min igual a 150. Contudo, tal técnica apresentou diversos agravantes, entre eles a dificuldade de ajuste dos três parâmetros sugeridos pelo autor. Além disso, a técnica gerou super-segmentação, Figura 3.6, em todos os casos testados, ocasionando, possivelmente, um aumento significativo na taxa de falso positivo. Por esses fatores, a segmentação de grafo através de cortes normalizados em multi-escala foi utilizada para a realização da segmentação das imagens mamográficas.




Figura 3.6: Resultado da técnica proposta por Felzenszwalb e Huttenlocher (2004) na imagem mdb058 (SUCKLING et al., 1994). (a) Imagem original com marcação do especialista em vermelho, (b) Resultado da técnica de segmentação proposta por Felzenszwalb e Huttenlocher (2004) com sigma igual à zero, k igual à 350 e min igual à 150.

3.3 *Redução de Falsos Positivos*

Uma difícil tarefa a ser realizada durante o desenvolvimento de sistemas CAD/CADx é obter um sistema sensível à anomalias, mas ao mesmo tempo reduzindo o número de falsos positivos gerados pela mesma.

A saída da etapa de segmentação de imagem é composta por múltiplos grupos onde todo pixel da imagem da imagem de entrada pertence a exatamente um grupo. Contudo, alguns desses grupos podem ser descartados facilmente por representarem regiões que apresentam características bem diferentes de uma região correspondente a uma massa. A remoção desses grupos além de conferir uma diminuição na taxa de falso positivo produzida, reduz o tempo computacional exigido pela metodologia.

Para esse fim, é empregada a etapa de Redução de Falsos Positivos. Esta etapa realiza uma análise individual das regiões produzidas na etapa de segmentação. A etapa de Redução de Falsos Positivos pode ser subdividida nas seguintes sub-etapas:




Figura 3.7: Procedimentos realizados na etapa de redução de falsos positivos

A primeira etapa da fase de Redução de Falsos Positivos leva em conta a média de intensidade e o desvio padrão da região analisada. Em geral, regiões de massas apresentam alta densidade, portanto, altos valores de intensidade na imagem. Em razão dessa característica, um dos critérios adotados para descarte dos grupos é a verificação da média da intensidade de cada grupo, sendo utilizado um limiar que avalia se essa região é suspeita ou não de apresentar uma massa.

Outro aspecto característico de regiões de massa é a homogeneidade da textura que esta região apresenta. Portanto, com o cálculo do desvio padrão das intensidades dos pixels presentes no grupo, alguns grupos que apresentam desvio padrão elevado podem ser descartados.

Contudo, utilizar um único limiar na verificação da média de intensidade e desvio padrão da região configura-se uma difícil tarefa, pois tais características são sensíveis à densidade da mama. Logo, este trabalho utiliza três categorias de imagens da mama de acordo com a densidade da mesma, estas categorias são: adiposa, levemente adiposa e densa. Cada uma dessas categorias possui um limiar próprio a ser utilizado na análise tanto do desvio padrão quanto da média de intensidade. Esta abordagem por si só já reduz consideravelmente o número de regiões que não correspondem a uma massa, como exibido na Figura 3.8.




Figura 3.8: Comparativo do resultado da fase de redução de falsos positivos. (a) Imagem mamográfica segmentada, (b) Um único grupo restante após a fase de redução de falsos positivos. Cada grupo gerado pela segmentação está representado por uma cor diferente na imagem e a demarcação em vermelho em (b) representa a região que o especialista destacou como suspeita

Para a descrição de cada região, é importante a análise não somente dos grupos em si, mas também das regiões vizinhas ao grupo. Tal abordagem garante uma descrição mais precisa e detalhada da região, visto que uma região vizinha a uma região de massa também possui características peculiares. Portanto, cada análise é feita em relação às seguintes extrações das regiões de interesse:

1. Cruz: A região é extraída em um formato de cruz, para isso, a região central da cruz corresponde ao menor quadrado envolvente à região e as quatro pontas da cruz são as regiões vizinhas da região central que distam 30 pixels da ROI.




Figura 3.9: Região extraída com formato de cruz.

2. Elipse: Região referente à menor elipse que envolve toda a região da ROI.




Figura 3.10: Região extraída com o formato da menor elipse envolvente.

3. GAP: A região extraída compreende um quadrado onde cada um dos seus lados possui um tamanho de 60 pixels maior em relação ao menor quadrado que envolve a região.




Figura 3.11: Região extraída com folga (GAP).

4. Somente ROI: A região extraída é exatamente a região segmentada, ou seja, o menor quadrado envolvente sem o fundo.




Figura 3.12: Extração da região igualmente como ela foi segmentada.

5. Mínimo Quadrado (*MINQUAD*): A região extraída corresponde ao menor quadrado envolvente.




Figura 3.13: Região extraída equivalente ao menor quadrado envolvente da região.

Na etapa de Descrição das Regiões Extraídas é realizada a extração de atributos dos grupos oriundos da etapa anterior para que, posteriormente, esses dados possam ser analisados e classificados, transformando assim informação em conhecimento.

Para descrever as características das regiões, cada região é quantizada em oito níveis diferentes: 8, 16, 32, 64, 128, 256. Ao quantificar a imagem em um nível abaixo do atual é possível que regiões sutilmente diferentes passem a possuir a mesma intensidade de cor, pois a cada redução na quantização, menos níveis de cinza são disponibilizados para representar a imagem. Dessa forma, regiões que são constituídas do mesmo material, mas que na imagem mamográfica apresentam características visuais diferentes devido a diversos fatores, tais como sensibilidade errônea do mamógrafo, mal manuseio do equipamento ou exposição à diferentes quantidade de raios-x, podem ser representadas visualmente de forma igual, resultando assim em uma descrição igual para ambas as regiões.

Para cada quantização de imagem realizada, são geradas as matrizes de co-ocorrência e run-length. Quando utilizada a matriz de co-ocorrência, são geradas 20 matrizes, onde cada uma representa uma combinação entre um dos quatro ângulos adotados (0° , 45° , 90° e 135°) e uma das cinco distâncias adotadas (de 1 à 5). Já para a descrição com o uso de matriz run-length, são geradas 4 matrizes, cada uma para um dos ângulos adotados (0° , 45° , 90° e 135°). Para cada uma das matrizes geradas, são calculados os índices de Simpson, Shannon ou McIntosh levando-se em consideração apenas os indivíduos descritos nestas matrizes.

Após a descrição das regiões, a MVS é utilizada para a tarefa de classificação dessas regiões. Foram experimentados vários modos de treinamento da MVS, a fim de observar aquele que melhor se adequava aos propósitos deste trabalho. Durante o treinamento, foram utilizadas quantidades iguais de cada classe para a criação do modelo da MVS. Esta quantidade foi variada em forma percentual, de 50% a 80%, em incrementos de 10%, em relação à quantidade de regiões malignas presentes em cada base, pois em todas essas bases a quantidade de regiões sadias é superior à quantidade de regiões com alguma neoplasia.

4 Testes e Resultados

Para fins de testes, foram utilizadas somente as imagens do banco de dados MIAS (SUCKLING et al., 1994) que apresentam pelo menos uma região de massa, totalizando assim 74 imagens. As imagens presentes neste banco de dados já estão categorizadas em uma das seguintes categorias: adiposa, levemente adiposa e densa. Dessas 74 imagens, 29 encontram-se na categoria adiposa, enquanto que a categoria levemente adiposa possui 26 imagens e, por fim, 19 imagens são pertencentes à categoria de imagens densas.

O cálculo do limiar tanto do desvio padrão quanto da média de intensidade utilizado como critério de descarte de regiões foi calculado individualmente para cada um dos grupos de imagens citados. O cálculo do limiar utilizado baseou-se em uma análise da média de intensidade e desvio padrão das regiões anômalas encontradas em cada uma das categorias. Para este cálculo foram utilizadas 10 imagens que mais representavam cada categoria. Os valores obtidos são demonstrados na Tabela 4.1.

Tabela 4.1: Limiares utilizados para o descarte de regiões com base a média de intensidade e desvio padrão

Classificação	Média de Intensidade	Desvio Padrão
Adiposas	130	37
Levemente Adiposas	130	35
Densas	179	35

Durante a segmentação, cada imagem foi segmentada em três quantidades diferentes de regiões: 35, 45 e 55. Aplicando-se os limiares obtidos em cada categoria, foram obtidos os resultados exibidos nas Tabelas 4.2, 4.3 e 4.4.

Uma das principais preocupações durante a fase de descarte de regiões é maximizar o número de descarte de regiões que não correspondem a uma massa ao passo em que seja mantido ao menos uma região de massa por imagem. Dado esse objetivo é perceptível que para os limiares utilizados, a segmentação em 45 grupos apresentou os melhores resultados, apresentando uma imagem em cada categoria onde a região de massa foi perdida, totalizando 3 imagens, enquanto que a segmentação em 35 grupos apresentou 8 imagens que perderam as regiões de massa e que a segmentação em 55 grupos gerou a

Tabela 4.2: Comparativo das segmentações produzidas para imagens do grupo adiposa

Quantidade de Regiões	Quantidade total de regiões antes do descarte	Quantidade de regiões de massa após o descarte	Quantidade de regiões que não apresentam massa após o descarte	Quantidade de imagens que perderam todas as regiões de massa após o descarte.
35 Grupos	1015	68	234	2
45 Grupos	1305	82	334	1
55 Grupos	1595	100	428	1

Tabela 4.3: Comparativo das segmentações produzidas para imagens do grupo levemente adiposas

Quantidade de Regiões	Quantidade total de regiões antes do descarte	Quantidade de regiões de massa após o descarte	Quantidade de regiões que não apresentam massa após o descarte	Quantidade de imagens que perderam todas as regiões de massa após o descarte.
35 Grupos	910	74	209	1
45 Grupos	1170	83	303	1
55 Grupos	1430	101	398	1

Tabela 4.4: Comparativo das segmentações produzidas para imagens do grupo das densas

Quantidade de Regiões	Quantidade total de regiões antes do descarte	Quantidade de regiões de massa após o descarte	Quantidade de regiões que não apresenta massa após o descarte	Quantidade de Imagens que perdeu todas as regiões de massa após o descarte.
35 Grupos	665	19	93	5
45 Grupos	885	31	120	1
55 Grupos	1045	34	151	2

perda das regiões de massa em 4 imagens.

Utilizando as imagens segmentadas em 45 grupos e aplicando os limiares utilizados em cada categoria para o descarte das regiões com base na média de intensidade e desvio padrão, o número de regiões foi reduzido em torno de 71,6%.

As regiões remanescentes dessa avaliação inicial foram classificadas através do uso de Máquinas de Vetores de Suporte. Foram geradas diversas bases de características, cada uma com uma combinação entre um dos índices de diversidade apresentados juntamente com uma ou nenhuma das matrizes de descrição de textura.

Para as bases que utilizam somente um índice de diversidade sem nenhuma matriz de descrição de textura, cada região foi descrita utilizando seis atributos, cada um correspondente ao índice de diversidade para cada um dos seis níveis de quantizações utilizados.

Já as bases que combinam a matriz de co-ocorrência com um dos índices de diversidade, as regiões são descritas em cento e vinte atributos. Cada um desses atributos corresponde à combinação dos seis níveis de quantização com as cinco distâncias e os quatro ângulos utilizados pela matriz de co-ocorrência.

Por fim, para as bases que combinam a matriz run-length com um dos índices de diversidade, as regiões são descritas em vinte e quatro atributos. Cada um dos atributos é uma combinação entre um dos seis níveis de quantização adotados juntamente com um dos quatro ângulos utilizados para a construção da matriz run-length.

Durante o treinamento da Máquina de Vetores de Suporte, a quantidade de amostras das duas classes (massa e não massa) foi selecionada de forma percentual com relação à base de regiões que apresentam massa. Essa porcentagem foi variada entre 50% a 80%, incrementando em etapas de 10 e, para cada modelo gerado, o mesmo processo foi repetido cinco vezes para evitar que o critério de escolha aleatória das amostras para o treinamento não interferisse no resultado final.

Novamente, como o principal objetivo da metodologia é reduzir a quantidade de falsos positivos ao passo que minimize a perda de regiões com alguma lesão, a Tabela 4.5 apresenta os melhores resultados obtidos após a classificação com a Máquina de Vetores de Suporte levando-se em consideração os resultados com as melhores taxas de sensibilidade.

Pelos resultados, percebe-se que os melhores resultados não utilizam as matrizes

Tabela 4.5: Cinco melhores resultados da classificação com base nos melhores valores de sensibilidade. Os valores demonstrados de VP, FP, VN E FN são relativos aos valores médios das cinco execuções realizadas sob mesma configuração da MVS.

Base	Porcent.	\overline{VP}	\overline{FP}	\overline{VN}	\overline{FN}	Acc %	Sens %	Espec %
Extração: GAP Índice: Simpson Matriz: Nenhuma	60%	65	376	264	14	45,75	82,27	41,25
Extração: Cruz Índice: McIntosh Matriz: Nenhuma	70%	46,4	354,4	265,6	12,6	45,94	78,64	42,83
Extração: GAP Índice: shannon Matriz: Nenhuma	80%	31,4	332,8	268,2	8,6	46,73	78,5	44,62
Extração: Cruz Índice: McIntosh Matriz: Nenhuma	80%	31	332,4	268,6	9	46,73	77,5	44,69
Extração: Cruz Índice: Simpson Matriz: Nenhuma	70%	45	344,2	275,8	14	47,24	76,27	44,48

de descrição de textura para o cálculo dos índices de diversidade. O melhor resultado com descrição de textura (Sétimo lugar) foi obtido com a matriz de co-ocorrência com o índice de Shannon utilizando a extração em forma da região em forma de cruz com um percentual de 80% das amostras de massas para o treinamento da MVS. Para esta configuração, foi obtida uma taxa média de 30,2 verdadeiros positivos; 235 falsos positivos; 366 verdadeiros negativos e 9,8 falsos negativos; resultando assim em uma acurácia de 61,8%; sensibilidade de 75,5% e com 60,89% de especificidade.

Pelos resultados mostrados pela Tabela 4.6 é perceptível a influência da quantidade de amostras utilizadas durante o treinamento da MVS no resultado final. Percebe-se que a melhor configuração correspondeu a de 60% para treinamento. Este também foi o caso onde houve a menor especificidade, resultando na menor redução de falso positivos, mas mantendo a melhor taxa de acertos em massa o que corresponde no objetivo básico da metodologia.

A Tabela 4.7 demonstra o resultado obtido para o índice de Simpson sem nenhuma matriz, variando a forma de extrair as regiões. Para esta combinação, as duas

Tabela 4.6: Resultados obtidos com a mesma descrição, porém com mudança na porcentagem das amostras utilizadas para o treinamento da MVS.

Base	Porcent.	\overline{VP}	\overline{FP}	\overline{VN}	\overline{FN}	Acc %	Sens %	Espec %
Extração: GAP Índice: Simpson Matriz: Nenhuma	50%	58,4	328,8	330,2	39,6	51,33	59,59	50,10
Extração: GAP Índice: Simpson Matriz: Nenhuma	60%	65	376	264	14	45,75	82,27	41,25
Extração: GAP Índice: Simpson Matriz: Nenhuma	70%	44,4	345,8	274,2	14,6	46,92	75,25	44,22
Extração: GAP Índice: Simpson Matriz: Nenhuma	80%	29,4	338	263	10,6	45,61	73,5	43,76

melhores formas de extrair as regiões levando em consideração a taxa de especificidade pertencem a extração no formato de GAP e cruz, respectivamente. Apesar desta combinação emitir uma maior taxa de sensibilidade para a extração na forma MINQUAD, seguido do formato de cruz e GAP; no geral, a extração em formato de cruz e GAP apresentaram as melhores taxas de sensibilidade do que a extração utilizando MINQUAD. Essas características reforçam o que pode ser visto na Tabela 4.5 onde todos os cinco melhores resultados foram extraídos em formato de GAP ou cruz. Percebe-se que a extração original que não leva em consideração regiões exteriores a que foi segmentada tem menos poder de discriminação do que aquela que leva em consideração regiões exteriores

Tabela 4.7: Resultados obtidos com variação na forma de extrair a região da imagem

Base	Porcent.	\overline{VP}	\overline{FP}	\overline{VN}	\overline{FN}	Acc %	Sens %	Espec %
Extração: GAP Índice: Simpson Matriz: Nenhuma	50%	58,4	328,8	330,2	39,6	51,33	59,59	50,10
Extração: CRUZ Índice: Simpson Matriz: Nenhuma	50%	61,8	329,6	329,4	36,2	51,67	63,06	49,98
Extração: ELIPSE Índice: Simpson Matriz: Nenhuma	50%	55	336	323	43	49,93	56,12	49,01
Extração: ROI Índice: Simpson Matriz: Nenhuma	50%	56,2	348	311	41,8	48,50	57,34	47,19
Extração: MINQUAD Índice: Simpson Matriz: Nenhuma	50%	66,6	399	260	31,4	43,14	67,95	39,45

5 Conclusão

Diante dos problemas enfrentados diariamente por profissionais da saúde na tarefa de identificar neoplasias presentes na mama através das imagens radiográficas da mesma, os sistemas computacionais de auxílio à detecção e diagnósticos têm demonstrado ser de grande utilidade para realização dessas tarefas, proporcionando uma redução nos casos de falsos negativos e, conseqüentemente, elevando o grau de confiança no diagnóstico médico.

Por outro lado, o emprego desses sistemas têm evitado que alguns procedimentos invasivos tenham que ser realizados para constatar a opinião médica sobre o caso analisado. Além disso, as técnicas computacionais apresentadas têm sido cada vez mais úteis na tentativa de melhorar a qualidade da imagem em análise, visto que, em grande parte, a qualidade da imagem adquirida está diretamente relacionada com a tecnologia empregada nos mamógrafos e a aquisição de mamógrafos modernos implica em alto custo financeiro.

É válido salientar que apesar das grandes contribuições dadas por sistemas de apoio à decisão, nenhum desses sistemas visa substituir ou invalidar o diagnóstico médico, mas sim corroborar e garantir mais confiabilidade tanto para o médico quanto ao paciente.

A metodologia apresentada neste trabalho mostrou-se promissora no sentido de identificar e classificar anormalidades presentes no parênquima mamário, ao mesmo tempo que as abordagens adotadas proporcionam uma redução na taxa de emissão de falsos positivos.

Apesar dos bons resultados produzidos pela técnica de segmentação adotada neste trabalho, o custo computacional que a técnica requer é relativamente alto. Portanto, é desejável que ao invés de segmentar a imagem mamográfica como um todo, somente seja segmentado o parênquima mamário, reduzindo assim o custo computacional e ao mesmo tempo utilizando todos os grupos produzidos para clusterizar apenas as estruturas internas da mama, proporcionando uma segmentação mais coesa e eficaz.

A princípio, é necessário que um usuário do sistema informe a qual categoria de densidade que a imagem sob investigação pertence. Contudo, é desejável que a própria metodologia induza a densidade da imagem analisada através da verificação das

características presentes no parênquima mamário.

Os Índices de Diversidade mostraram-se uma maneira promissora de descrever a textura das regiões analisadas. Além disso, é notável que a forma como as regiões são extraídas da imagem e as técnicas utilizadas na descrição das regiões influenciam diretamente nos resultados obtidos com as Máquinas de Vetores de Suporte. Quando a região suspeita é extraída juntamente com sua região vizinha há uma melhora nos resultados produzidos pela Máquina de Vetores de Suporte. Essa melhora é devido ao enriquecimento da descrição através do uso das características peculiares presentes nas regiões vizinhas. Estes resultados demonstram que caso seja utilizado somente as características da região suspeita para a descrição da região, informações discriminatórias particularmente importantes para o processo de reconhecimento de padrões visando a redução de falsos positivos podem ser deixadas de fora.

Dado o grande número de bases produzidas pela combinação das técnicas apresentadas neste trabalho, é importante que além das análises comparativas já realizadas nos testes apresentados sejam também realizadas outras formas de analisar o desempenho de cada abordagem de forma comparativa, como por exemplo através do uso do FROC (CHAKRABORTY; WINTER, 1990).

Referências Bibliográficas

- AZEVEDO, C. M. de; PEIXOTO, J. E. *Falando sobre Mamografia*. 1993.
- BIRD, R.; WALLACE, T.; YANKASKAS, B. Analysis of cancers missed at screening mammography. *Radiology*, Radiological Society of North America, v. 184, n. 3, p. 613–617, 1992.
- CHAKRABORTY, D.; WINTER, L. Free-response methodology: alternate analysis and a new observer-performance experiment. *Radiology*, Radiological Society of North America, v. 174, n. 3, p. 873–881, 1990.
- CHAVES, A. d. C. F. *Extração de regras fuzzy para Máquinas de vetor de Suporte (SVM) para classificação em múltiplas classes*. Tese (Doutorado) — Tese de Doutorado. Pontifícia Universidade Católica do Rio de Janeiro, 2006.
- CORTES, C.; VAPNIK, V. Support-vector networks. *Machine learning*, Springer, v. 20, n. 3, p. 273–297, 1995.
- DOU. Diário Oficial da União. *Diário Oficial da República Federativa do Brasil*. 2008. 1 p. 29 de abril de 2008.
- FELZENSZWALB, P. F.; HUTTENLOCHER, D. P. Efficient graph-based image segmentation. *International Journal of Computer Vision*, Springer, v. 59, n. 2, p. 167–181, 2004.
- FREER, T. W.; ULISSEY, M. J. Screening mammography with computer-aided detection: Prospective study of 12,860 patients in a community breast center1. *Radiology*, Radiological Society of North America, v. 220, n. 3, p. 781–786, 2001.
- GALLOWAY, M. M. Texture analysis using gray level run lengths. *Computer graphics and image processing*, Elsevier, v. 4, n. 2, p. 172–179, 1975.
- GONZALEZ, R. C.; WOODS, R. E. *Digital Image Processing (3rd Edition)*. 3. ed. [S.l.]: Prentice Hall, 2007. Hardcover. ISBN 013168728X.

GOPAL, G.; KANAGA, E. G. M. A study on enhancement techniques for mammogram images. *International Journal of Advanced Research in Electronics and Communication Engineering*, v. 2, n. 1, p. pp-036, 2013.

GULIATO, D.; BARCELOS, C. A. Z.; DIAS, W. B. O uso de equações de difusão no processo de detecção de regiões suspeitas em mamografias. *SBC*, p. 121, 2008.

HAIKIN, S. *Neural networks: a comprehensive foundation*. Pearson Education, 1998.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. H. Textural features for image classification. *Systems, Man and Cybernetics, IEEE Transactions on*, IEEE, n. 6, p. 610–621, 1973.

HAYKIN, S. S. *Redes neurais-princípios e prática*. Porto Alegre - RS: Bookman, 2001.

HUYNH, P. T.; JAROLIMEK, A. M.; DAYE, S. The false-negative mammogram. *Radiographics*, Radiological Society of North America, v. 18, n. 5, p. 1137–1154, 1998.

INCA. Instituto Nacional do Câncer. *Estimativa 2012*. 2012. <http://www.inca.gov.br/estimativa/2012/index.asp?ID=2>. Acessado em 13 de fevereiro de 2013.

JO, E.-B. et al. Detection of breast cancer based on texture analysis from digital mammograms. *Intelligent Autonomous Systems 12*, Springer, p. 893–900, 2013.

MALIK, J. et al. Contour and texture analysis for image segmentation. *International Journal of Computer Vision*, Springer, v. 43, n. 1, p. 7–27, 2001.

MCINTOSH, R. P. An index of diversity and the relation of certain concepts to diversity. *Ecology*, JSTOR, p. 392–404, 1967.

MEYER, F. Iterative image transformations for an automatic screening of cervical smears. *Journal of Histochemistry & Cytochemistry*, SAGE Publications, v. 27, n. 1, p. 128–135, 1979.

PANETTA, K. et al. Nonlinear unsharp masking for mammogram enhancement. *Information Technology in Biomedicine, IEEE Transactions on*, IEEE, v. 15, n. 6, p. 918–928, 2011.

SAMPAIO, W. B. et al. Detection of masses in mammogram images using cnn, geostatistic functions and svm. *Computers in biology and medicine*, Elsevier, v. 41, n. 8, p. 653–664, 2011.

- SHANNON, C. E. A mathematical theory of communication. *ACM SIGMOBILE Mobile Computing and Communications Review*, ACM, v. 5, n. 1, p. 3–55, 2001.
- SHI, J.; MALIK, J. Normalized cuts and image segmentation. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, IEEE, v. 22, n. 8, p. 888–905, 2000.
- SIMPSON, E. H. Measurement of diversity. *Nature; Nature*, 1949.
- SUCKLING, J. et al. The mammographic images analysis society digital mammogram database. *Experta Medica International Congress Series*, v. 1069, p. 375–378, 1994.
- SUS. Sistema Único de Saúde. BRASIL. Ministério da Saúde. *Mamografias realizadas no SUS crescem 41%*. 2012. 02 de fevereiro de 2013.
- VALE, E. E. Título: Realce de imagens no domínio da transformada. 2006.
- VAPNIK, V. N.; CHERVONENKIS, A. Y. On the uniform convergence of relative frequencies of events to their probabilities. *Theory of Probability & Its Applications*, SIAM, v. 16, n. 2, p. 264–280, 1971.
- WHO. World Health Organization. *Cancer Definition*. 2012. <http://www.who.int/mediacentre/factsheets/fs297/en/>. Acessado em 05 de janeiro de 2013.
- WIRTH, M.; FRASCHINI, M.; LYON, J. Contrast enhancement of microcalcifications in mammograms using morphological enhancement and non-flat structuring elements. p. 134–139, 2004.
- ZHANG, L. et al. A novel automatic tumor detection for breast cancer ultrasound images. v. 1, p. 401–404, 2011.
- ZUIDERVELD, K. Contrast limited adaptive histogram equalization. p. 474–485, 1994.