Universidade de São Paulo
Escola de Engenharia de São Carlos
Departamento de Engenharia Elétrica

**ATRIBUTOS VISUAIS PARA RECUPERAÇÃO
BASEADA EM CONTEÚDO DE IMAGENS
MAMOGRÁFICAS**

Sérgio Koodi Kinoshita

DEDALUS - Acervo - EESC

Serviço de Pós-Graduação EESC/USP

EXEMPLAR REVISADO

Data de entrada no Serviço...16./09./04...

Ass.:

Tese apresentada ao Departamento de Engenharia Elétrica, Escola de Engenharia de São Carlos, da Universidade de São Paulo, para obtenção do título de Doutor em Engenharia Elétrica.

Orientadores:

Prof. Dr. Paulo M. de Azevedo Marques
Profa. Dra. Annie France Frère

São Carlos
2004

FOLHA DE JULGAMENTO

Candidato: Engenheiro **SÉRGIO KOODI KINOSHITA**

Tese defendida e julgada em 11-08-2004 perante a Comissão Julgadora:

Prof. Dr. **PAULO MAZZONCINI DE AZEVEDO MARQUES** (Orientador)
(Faculdade de Medicina de Ribeirão Preto/USP) **Aprovado**

Prof. Associado **ADILSON GONZAGA**
(Escola de Engenharia de São Carlos/USP) **APROVADO**

Prof. Dr. **NELSON DELFINO D'ÁVILA MASCARENHAS**
(Universidade Federal de São Carlos/UFSCar) **APROVADO**

Prof. Dr. **CLÓVIS SIMÃO TRAD**
(Faculdade de Medicina de Ribeirão Preto /USP) **Aprovado**

Profª. Associada **ROSELI APARECIDA FRANCELIN ROMERO**
(Instituto de Ciências Matemáticas e de Computação/USP) **APROVADO**

Prof. Associado **MURILO ARAUJO ROMERO**
Coordenador do Programa de Pós-Graduação
em Engenharia Elétrica

Profª. Titular **MARIA DO CARMO CALIJURI**
Presidente da Comissão de Pós-Graduação

“O que vale na vida não é o ponto de partida e sim a caminhada. Caminhando e semeando, no fim terás o que colher.”

Cora Coralina

DEDICATÓRIA

Á *Angela*, minha esposa e companheira pelo amor e esforço dedicado para que eu completasse essa caminhada com sucesso.

Aos meus filhos *Daniele, Tiago e Cássia* pela compreensão e amor singelo sempre dedicado a mim.

Aos *meus pais* que foram deste mundo, mas deixaram saudade.

AGRADECIMENTOS

Aos meus queridos irmãos, cunhadas e cunhados que sempre me incentivaram e hoje elevo ainda mais o meu apreço.

Ao Professor Doutor Paulo M. de Azevedo Marques, orientador e amigo, que aceitou o desafio da orientação deste trabalho mesmo sabendo das dificuldades de tempo e espaço. Obrigado pela acolhida em sua casa.

À Professora Doutora Annie F. Frère que desde a graduação me ensinou a respeitá-la pela sua sabedoria e generosidade.

Aos amigos do laboratório CHOPi Roberto (Chico Bento), Honda, Lucas, Edilson, Marcelo, Gustavo, David, Luciano e Rodrigo pela amizade e companheirismo. Aos meus amigos Chico, Honda e Lucas, o meu agradecimento especial pela ajuda e disposição dispensada durante o doutorado.

Aos colegas do laboratório ALADIM Leandro, Marcelo, Silvia, Barreiro, Silvio, Clayton e Flávio pela ajuda e incentivo.

À coordenação de pós-graduação por permitir a minha presença como aluno do programa de doutorado.

Aos professores e funcionários do Departamento de Engenharia Elétrica, em especial a Denise, Marisa e Rosane pela competência e boa vontade.

Aos professores e pesquisadores do Centro das Ciências da Imagem e Física Médica (CCIFM) do Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto, em especial ao Dr. Clóvis Simão Trad e Dr. José Antonio H. Rodrigues pelo auxílio na análise das imagens.

As secretárias Rita e Fabrícia do CCIFM pela colaboração e presteza de seus serviços.

Aos meus amigos e colegas da Universidade de Marília pelo apoio e torcida.

Ao professor doutor Nelson Mascarenhas pela ajuda e discussão de algumas técnicas utilizadas neste trabalho.

E a todos que de forma direta ou indireta participaram deste trabalho.

SUMÁRIO

Lista de Figuras	x
Lista de Siglas e Abreviaturas	xv
Resumo.....	xvii
Abstract.....	xix

Capítulo 1

Introdução.....	1
1.1 Os padrões de classificação da mama de acordo com a densidade dos tecidos mamários.....	2
1.2 Padrões de localização baseados em áreas da mama.....	5
1.3 Incidências básicas em mamografias.....	6
1.4 Análise em mamografia pelo radiologista.....	7
1.5 Sistema computacional de auxílio ao diagnóstico (CAD)...	8
1.6 Sistema de recuperação de imagem baseada em conteúdo (CBIR).....	11
1.7 Objetivo e justificativa desta pesquisa.....	13
1.8 Organização da tese.....	19

Capítulo 2

Revisão Bibliográfica.....	20
2.1 Análise de densidade mamária em sistema CBIR.....	20
2.2 Análise de densidade mamária em sistema CAD.....	21
2.3 Preparação da imagem e processamento de imagem.....	23
2.3.1 Tratamento de ruídos em mamogramas digitalizados.	23
2.3.2 Segmentação automática da região da mama.....	23
2.3.3 Detecção automática da linha da região do músculo peitoral.....	25
2.3.4 Detecção automática do mamilo.....	27
2.3.5 Segmentação da região fibro-glandular em mamografia.....	28

Capítulo 3

Base de dados, preparação das imagens e programas utilizados.....	29
3.1 Digitalização dos filmes mamográficos.....	30
3.2 Recorte da imagem mamográfica digitalizada.....	31
3.3 Programas utilizados.....	32

Capítulo 4

Pré-processamento das imagens para retirada de ruídos e recuperação da borda da região da mama em mamogramas digitalizados.....	34
4.1 Equação de Difusão Anisotrópica.....	35
4.2 Equação de Difusão Anisotrópica com filtro de Wiener.....	36
4.3 Avaliação dos processos de avaliação do ruído e restauração da borda da região da mama.....	38

Capítulo 5

Segmentação da região da mama em mamogramas digitalizados.....	39
5.1 Método de Limiarização.....	40
5.1.1 Princípio de máxima entropia.....	42
5.1.2 Método de Otsu.....	42
5.1.3 Método de preservação de momento.....	43
5.1.4 Método iterativo de Ridler & Salvard.....	44
5.1.5 Método iterativo de Reddi.....	45
5.1.6 Método da matriz de co-ocorrência.....	46
5.2 Preparação das imagens para o processo de segmentação.	48
5.3 Obtenção do valor de limiar ótimo e avaliação do processo de segmentação.	48
5.4 Remoção de artefatos e suavização inicial da borda da imagem segmentada.....	49
5.5 Suavização final com a aplicação da interpolação B_3 -spline.	50
5.6 A imagem segmentada e a avaliação do processo de restauração	51

Capítulo 6

Detecção automática da região do músculo peitoral, localização da posição do mamilo e segmentação da região dos tecidos fibro-glandulares.....	55
6.1 A transformada de Radon	55
6.2 Detecção da região de músculo peitoral pela transformada de Radon	57
6.3 Avaliação da detecção da linha da região do músculo peitoral pela transformada de Radon.....	59
6.4 Localização do mamilo pela transformada de Radon.....	62
6.5 Avaliação da localização do mamilo.....	63
6.6 Segmentação da região fibro-glandular.....	65

Capítulo 7

Extração de atributos visuais em mamogramas.....	67
7.1 Modelo de divisão da mama em quadrantes	68
7.2 Atributos de forma	69
7.2.1 Medida de área.....	70
7.2.2 Medida de razão de diâmetro.....	71
7.2.3 Medida de solidez.....	72
7.3 Atributos de textura de Haralick.....	73
7.4 Atributos de momento de Hu.....	76
7.5 Atributos de momentos estatísticos do Histograma da imagem.....	78
7.6 Medida de granulometria como atributo de textura.....	79
7.7 Extração de atributos no domínio de Radon.....	80

Capítulo 8

Processo de seleção de atributos e recuperação das imagens.....	85
8.1 Seleção de atributos.....	86
8.1.1 Normalização dos valores de atributos.....	86
8.1.2 Redução da dimensionalidade do conjunto de atributos.....	87
8.2 Definição dos grupos de amostras de treinamento e teste.....	87

8.3	A rede neural de mapa auto-organizável de Kohonen na recuperação de imagens.....	88
8.3.1	Arquitetura da rede de mapa auto-organizável de Kohonen.....	88
8.4	Os parâmetros adotados para a classificação das imagens.	90
8.5	Técnica de alinhamento entre as imagens.....	91
8.6	A medida de similaridade entre as imagens.....	92

Capítulo 9

Resultados e Discussão.....	94
9.1 Base de imagens, preparação e processamento das imagens.....	94
9.1.1 Base de imagens e preparação das imagens.....	94
9.1.2 Processo de retirada do ruído e restauração da borda.....	95
9.1.3 Processo de segmentação da região da mama.....	96
9.1.4 Processo de detecção da linha da região do músculo peitoral.....	100
9.1.5 Processo de detecção do mamilo.....	104
9.1.6 Processo de segmentação da região de tecidos fibro-glandulares.....	105
9.1.7 Considerações finais desta etapa.....	106
9.2 Extração e seleção de atributos visuais.....	108
9.3 As imagens recuperadas e a comparação por similaridade .	109
9.3.1 Avaliação pela classificação da composição dos tecidos	110
9.3.2 Avaliação pelo coeficiente de correlação	117

Capítulo 10

Conclusões finais.....	123
10.1 Proposta para trabalhos futuros.....	125
10.2 Publicações relacionadas a este tese.....	126
Referências Bibliográficas.....	127

Lista de Figuras

FIGURA 1.1: Métodos do sistema de quadrantes e do relógio para descrição de informações da mama	6
FIGURA 1.2: Técnica de posicionamento da paciente na aquisição da imagem nas duas incidências. À esquerda, a incidência crânio-caudal (CC) e à direita, a médio-lateral-oblíqua (MLO).	7
FIGURA 1.3: Diagrama de Bloco do sistema de recuperação de imagem baseado em conteúdo.....	15
FIGURA 1.4: Diagrama de blocos da etapa de preparação e processamento da imagem.....	16
FIGURA 1.5: Diagrama de bloco da etapa de extração e seleção de atributos	17
FIGURA 1.6: Diagrama de blocos da etapa de classificação e comparação por similaridade.....	18
FIGURA 3.1: Transformação escalar das imagens. Na primeira coluna, é ilustrado o recorte realizado na imagem (cinza mais claro) para retirada da identificação da paciente (cinza escuro). Na coluna do meio é feito o acréscimo de uma matriz de pixels nos dois lados da imagem para obter uma imagem de matriz quadrada. Na coluna mais à direita a imagem é redimensionada para 1024x1024 pixels.....	32
FIGURA 3.2: Transformação de resolução espacial da imagem. Em (a), a imagem original possui matriz de 2126x2835 pixels. Em (b), a imagem possui matriz de 1024x1024 pixels após a transformação de recorte e redimensionamento com interpolação bi-linear.....	33
FIGURA 4.1: Ilustra a aplicação da equação de difusão anisotrópica com pré-filtragem. Em (a) a imagem original ruidosa, em (b) aplicado filtro gaussiano, em (c) aplicado o filtro morfológico e em (d) o filtro de Wiener.....	38
FIGURA 5.1: Histogramas típicos de imagens da incidência crânio-caudal direita (CCD) apresentando densidade dos tecidos mamários de acordo com o padrão BI-RADS™: (a) composição 1; (b) composição 2; (c) composição 3; (d) composição 4. Os valores do eixo das ordenadas dos histogramas correspondem à quantidade de pixels para cada nível de cinza (0-255).....	41
FIGURA 5.2: Histogramas típicos das mesmas imagens da figura 5.1 de incidência medio-lateral oblíqua direita (MLOD), apresentando densidade dos tecidos mamários de acordo com o padrão BI-RADS. (a) composição 1; (b) composição 2; (c) composição 3; (d) composição 4. Os valores do eixo das ordenadas dos histogramas correspondem à quantidade de pixels para cada nível de cinza	

(0-255).....	41
FIGURA 5.3: Definição dos ângulos usados na matriz de co-ocorrência.....	46
FIGURA 5.4: (a) exemplo de matrizes de co-ocorrência com $d=1$ de uma imagem 4x4 com 4 níveis de cinza (0-3). (b) $\theta = 135^\circ$; (c) $\theta = 90^\circ$; (d) $\theta = 45^\circ$; (e) $\theta = 0^\circ$..	47
FIGURA 5.5: (a) apresenta uma imagem da base de imagens e a limiarização realizadas pelos métodos: (b) PME, (c) MPM, (d) OTSU, (e) RIDLER, (f) MMCO, (g) e (h) REDDI	52
FIGURA 5.6: (a) apresenta uma imagem da base de imagens e a limiarização realizadas pelos métodos: (b) PME, (c) MPM, (d) OTSU, (e) RIDLER, (f) MMCO, (g) e (h) REDDI	52
FIGURA 5.7: Mostra duas imagens após a limiarização e as operações de retirada de artefatos e objetos espúrios que permaneceram na imagem. Em (a) e (d), a imagem antes da limiarização; em (b) e (e), a imagem após a limiarização; em (c) e (f), a imagem após a aplicação do filtro morfológico de fechamento e abertura, rotinas para retirada de artefatos e objetos de fundo da imagem e a aplicação de interpolação b_3 -spline para suavização final da borda da mama.....	53
FIGURA 5.8: O resultado do processo de restauração da imagem. Em (a) e (d), a imagem original; em (b) e (e), após a pré-filtragem com Wiener e equação de Difusão Anisotrópica; e em (c) e (f), após os processos de segmentação, retirada de ruído e artefatos, e suavização.....	54
FIGURA 6.1: ilustra a função $A(x,y)$ na transformada de Radon $R(t,\theta)$	56
FIGURA 6.2: Comparação entre os mapeamentos da transformada de Hough e de Radon (Rangayyan, 1998).....	57
FIGURA 6.3: ilustração de uma imagem em nível de cinza (a) e sua transformada de Radon (b).....	60
FIGURA 6.4: ilustração de uma imagem binarizada com a detecção de borda realizada com o operador de Sobel (a) e sua transformada de Radon (b).....	60
FIGURA 6.5: Ilustra a detecção da linha que separa a região do músculo peitoral. Na imagem em nível de cinza (a) é aplicado o operador de detecção de borda de Canny com $\sigma=8$ (b) e a transformada de Radon para detecção das retas candidatas (c) e por um critério de intensidade no domínio de Radon e posição da reta, é seleciona da reta (d). As imagens foram equalizadas para visualização.....	61
FIGURA 6.6: Desenho ilustrativo de duas retas, r e s , para o cálculo do erro médio quadrático. São utilizados todos os pontos dentro dos limites da imagem da reta s e da reta r (linha cheia) e, neste exemplo, os pontos estendidos da reta r (linha pontilhada).....	61
FIGURA 6.7: ilustra a aplicação da transformada de Radon para detecção da posição do mamilo. (a) imagem da incidência CC; (b) a imagem após a aplicação do filtro TopHat; (c) imagem com as linhas selecionadas para determina o ponto de convergência (pc); (d) mostra a posição do ponto de convergência e do mamilo.	64
FIGURA 6.8: ilustra a aplicação da transformada de Radon para detecção da posição do mamilo. (a) imagem da incidência MLO; (b) a imagem após a aplicação do filtro TopHat; (c) imagem com as linhas selecionadas para determina o ponto de convergência (pc); (d) mostra a posição do ponto de convergência e do mamilo..	64

FIGURA 6.9: Seqüência de imagens para limiarização da região composta por tecido fibro-glandular. A imagem original (a) da vista CC foi submetida aos métodos de (b) Princípio de Máxima Entropia, (c) Método de Preservação de Momento e (c) Método de Otsu.....65

FIGURA 6.10: Seqüência de imagens para limiarização da região composta por tecido fibro-glandular. A imagem original (a) da vista MLO foi submetida aos métodos de (b) Princípio de Máxima Entropia, (c) Método de Preservação de Momento e (c) Método de Otsu.....66

FIGURA 7.1: Desenho ilustrativo da divisão da mama em sub-regiões.....71

FIGURA 7.2: Desenho ilustrativo da posição dos diâmetros extraídos para o cálculo da medida de razão de diâmetros.....72

FIGURA 7.3: Imagens binarizadas com formas diferentes.73

FIGURA 7.4: Processo de extração de atributo de medida de Granulometria. (a) imagem original; (b) imagem com a região de tecido fibro-glandular segmentada; (c) imagem numa etapa de filtragem de abertura morfológica; (d) o histograma da quantidade de pixels em função do raio de abertura do elemento estruturante.....81

FIGURA 7.5: Gráfico das funções de decomposição do domínio de Radon. (a) imagem da figura 6.7 com a região fibro-glandular segmentada; (b) Domínio de Radon $R(t, \theta)$; (c-d) as funções decompostas $R_1(\theta)$ e $R_2(t)$, respectivamente, do domínio de Radon.....83

FIGURA 8.1: Topologia da rede Som e as grades retangular e hexagonal de vizinhança de um neurônio vencedor.....91

FIGURA 8.2: Transformação escalar e de rotação de imagens para alinhamento. (a) e (b) as imagens originais; (b) e (d) as imagens transformadas.....93

FIGURA 9.1: (a) Imagem da incidência CC e o histograma correspondente abaixo; (b) imagem da incidência MLO e o histograma correspondente abaixo.....98

FIGURA 9.2: Imagens da etapa de restauração da borda e segmentação. (a) e (d) imagem original; (b) e (e) aplicação da equação de Difusão Anisotrópica com o filtro de Wiener, (c) e (f) processos de segmentação consideradas exatas.....99

FIGURA 9.3: Imagens da etapa de restauração da borda e segmentação. (a) e (d) imagem original; (b) e (e) após a aplicação da equação de Difusão Anisotrópica com o filtro de Wiener, (c) processo de segmentação considerada exata, (d) processo de segmentação considerada aceitável.....99

FIGURA 9.4: Imagens da etapa de restauração da borda e segmentação. (a) e (d) imagem original; (b) e (e) após a aplicação da equação de Difusão Anisotrópica com o filtro de Wiener, (c) e (d) processos de segmentação consideradas inaceitáveis.....100

FIGURA 9.5: Gráfico do número de imagens da incidência MLO direita em função do erro médio quadrático (E_{RMS}) entre a linha peitoral detectada de modo automático e manual. σ corresponde ao desvio-padrão do filtro de Canny.....103

FIGURA 9.6: Gráfico do número de imagens da incidência MLO esquerda em função do erro médio quadrático (E_{RMS}) entre a linha peitoral detectada de modo automático e manual. σ corresponde ao desvio-padrão do filtro de Canny.....103

FIGURA 9.7: Gráfico do número de imagens da incidência MLO direita e esquerda em função do erro médio quadrático (E_{RMS}) entre a linha peitoral detectada de modo automático e manual. σ corresponde ao desvio-padrão do filtro de Canny.....104

FIGURA 9.8: Gráfico do valor médio do Erro médio quadrático (E_{RMS}), em milímetro, entre a linha peitoral detectada de modo automático e manual em função do desvio-padrão σ do filtro de Canny das imagens da incidência MLO esquerda e direita juntas.....104

FIGURA 9.9: Imagem com exemplo de detecção errada da linha de músculo peitoral. (a) imagem original; (b) após a aplicação do detector de borda de Canny; (c) as linhas retas candidatas detectadas pela transformada de Radon; (d) a linha selecionada automaticamente (maior inclinação) e a definida manualmente (menor inclinação).....105

FIGURA 9.10: Erro raiz média quadrática (E_{RMS}) da detecção do mamilo para quatro imagens. (a) $E_{RMS} = 24,12$ mm; (b) $E_{RMS} = 9,80$ mm; (c) $E_{RMS} = 7,81$ mm; (d) $E_{RMS} = 0,95$ mm. O E_{RMS} corresponde distância entre os dois pontos brilhantes na imagem.....107

FIGURA 9.11: imagem preparada para a etapa de segmentação da região fibroglandular (a) Imagem da incidência CC e o histograma correspondente abaixo; (b) imagem da incidência MLO e o histograma correspondente abaixo.....108

FIGURA 9.12: Imagens recuperadas com o atributo espectral no domínio de Radon. Em (a) a imagem teste com composição 4, classificadas no padrão BI-RADS; em (b) imagem recuperada com composição 2; em (c) imagem recuperada com composição 3; e (d) imagem recuperada com composição 2.....111

FIGURA 9.13: Gráfico da taxa média de precisão da recuperação de imagens para um grupo de atributos. H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.....113

FIGURA 9.14: Gráfico da taxa média de precisão da recuperação de imagens para combinação de dois grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.....113

FIGURA 9.15: Gráfico da taxa média de precisão da recuperação de imagens para combinação de três grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.....114

FIGURA 9.16: Gráfico da taxa média de precisão da recuperação de imagens para combinação de quatro grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.....115

FIGURA 9.17: Gráfico da taxa média de precisão da recuperação de imagens para combinação de cinco grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.....116

FIGURA 9.18: Gráfico da taxa média de precisão da recuperação de imagens para combinação de todos os grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R:

espectrais no domínio de Radon; G: medida de Granulometria.....116

FIGURA 9.19: Gráfico do valor médio de precisão em função da revocação para 1 grupo de atributos. H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.....118

FIGURA 9.20: Gráfico do valor médio de precisão em função da revocação para 2 grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.....119

FIGURA 9.21: Gráfico do valor médio de precisão em função da revocação para 3 grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.....120

FIGURA 9.22: Gráfico do valor médio de precisão em função da revocação para 4 grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.....121

FIGURA 9.23: Gráfico do valor médio de precisão em função da revocação para 5 e 6 grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.....122

Lista de Abreviaturas e Siglas

ACR	American College of Radiology
ACS	American Cancer Society
BI-RADS	Breast Imaging Reporting and Data System
CAD	Computer-Aided Diagnosis
CBIR	Content-Based Image Retrieval
CBR	Colégio Brasileiro de Radiologia
CC	Crânio-Caudal (Incidência)
CCD	Crânio-Caudal Direita (Incidência)
CCE	Crânio-Caudal Esquerda (Incidência)
CCIFM	Centro das Ciências da Imagens e Física Médica
EM	Expectation-Maximization
E_{RMS}	Error Root Mean Square
FEBRASGO	Federação Brasileira de Sociedades de Ginecologia e Obstetrícia
HCFMRP	Hospital da Clínicas da Faculdade de Medicina de Ribeirão Preto
MLO	Médio-Lateral Oblíqua (Incidência)
MLOD	Médio-Lateral Oblíqua Direita (Incidência)
MLOE	Médio-Lateral Oblíqua Esquerda (Incidência)
MMCO	Método da Matriz de Co-ocorrência

MPM	Método de Preservação de Momento
OTSU	Método de Otsu
PCA	Principal Components Analysis
PME	Princípio de Máxima Entropia
QSE	Quadrante Superior Externo
QSI	Quadrante Superior Interno
QIE	Quadrante Inferior Externo
QII	Quadrante Inferior Interno
REDDI	Método iterativo de Reddi
RIDLER	Método iterativo de Ridler & Calvard
RNA	Rede Neural Artificial
ROI	Region of Interest
SBM	Sociedade Brasileira de Mastologia
SNR	Signal-Noise Ratio
SOM	Self-Organizing Maps
SVM	Support Vector Machine
TH	Transformada de Hough
TR	Transformada de Radon
USP	Universidade de São Paulo

Resumo

Atributos visuais de textura e forma foram investigados para a recuperação baseada em conteúdo de imagens mamográficas (CBIR). Para a similaridade de imagens, foi considerada a estrutura de densidade mamária, representada principalmente pelos tecidos fibro-glandulares. A pesquisa consistiu de três etapas: (1) Preparação e processamento das imagens; (2) Extração e seleção de atributos visuais de textura e forma; (3) Implementação de um sistema de recuperação de imagem. A primeira etapa consistiu dos processos de retirada de ruído do fundo da imagem, segmentação da região da mama, detecção da região de músculo peitoral, localização do mamilo e da segmentação da região de tecidos fibro-glandulares. Utilizou-se a equação de Difusão Anisotrópica com filtro de Wiener para retirada e suavização de ruídos encontrados na imagem e preservação da borda da mama. Para a segmentação da região da mama, foram utilizadas as técnicas de limiarização de Princípio de Máxima Entropia, Método de Preservação de Momento, Método de Otsu, Método iterativo de Ridler & Carvard, Método de Reddi e Método da Matriz de Co-ocorrência. A melhor imagem foi escolhida numa tarefa supervisionada. A detecção automática da região do músculo peitoral foi feita com a combinação do operador de Canny e a transformada de Radon como detector de linha. A posição do mamilo foi detectada com a transformada de Radon como detector de direção de densidade. A segmentação da região de tecidos fibro-glandulares foi feita também com as técnicas de limiarização do Princípio de Máxima Entropia, Método de Preservação de Momento, e Método de Otsu. Momentos Estatísticos extraídos do Histograma, Medida de Granulometria,

Momentos Estatísticos extraídos do Domínio de Radon, Momento de Hu, e Textura de Haralick foram investigados como atributos de textura. Medida de Área, Circularidade e Razão de Diâmetro foram investigados como atributos de forma. A rede de Mapas Auto-Organizáveis de Kohonen foi utilizada como sistema de recuperação de imagem. Foram utilizadas, neste trabalho, 1080 imagens do projeto de Banco de Imagens do HCFMRP-USP, módulo Mamografia. O treinamento e teste foram feitos com a técnica de “leaving-one-out” e os melhores resultados obtidos foram: Taxa de precisão de **91,07%** para a combinação dos cinco grupos de atributos de Forma, Estatísticos Extraídos do Histograma, Momento de Hu, Espectral no Domínio de Radon e de Medida de Granulometria; taxa de precisão e revocação do coeficiente de correlação médio representadas pela área sob a curva com valor de *0,02351* dos grupos de atributos de forma, de Textura de Haralick e Momento de Hu. Os resultados obtidos indicaram a relevância de nosso trabalho e seu potencial de utilização para a recuperação baseada em conteúdo de imagens mamográficas.

Palavra-chave: Recuperação de Imagem Baseada em Conteúdo, Processamento de Imagem Mamográfica, Equação de Difusão Anisotrópica, Transforma de Radon, Rede de Mapa Auto-Organizável de Kohonen, Filtro de Wiener, Medida de Granulometria.

Abstract

Visual texture based on texture and shape features were investigated for content-based mammographic images retrieval (CBIR). For similarity of images, the mammary density structures were considered, mainly represented by fibro-glandular tissues. This research consisted of three stages: (1) Images preparation and processing; (2) Extraction and selection of the visual features; (3) Implementation of a retrieval system. The first stage consisted of noisy removing from the image background, breast region segmentation, pectoral muscle region detection, nipple localization and the fibro-glandular tissues region segmentation. The equation of Anisotropic Diffusion was used with Wiener filter for noisy removing with the breast region edge preservation. For the breast region segmentation, the Thresholding techniques were used of Maximum Entropy Principle, Moment Preserving Method, Otsu Method, Ridler & Carvard Method, Reddi Method and Co-occurrence Matrix Method. The better image was chosen in a supervised task. The automatic pectoral muscle region detection was made with the Canny operator and Radon Transform combination as straight line detector. The nipple position was detected with the Radon Transform as density direction detector. The fibro-glandular tissues region was also defined with the thresholding techniques of the Maximum Entropy Principle, Moment Preserving Method, and Otsu Method. The Statistical Moments extracted from the Histogram, Measured of Granulometry, Statistical Moments extracted in Radon Domain, Moment of Hu, and Haralick Textures were investigated as texture features. Area, Circularity and Diameter Ratio were investigated as shape features. The Self-Organizing Maps of Kohonen was

used as image retrieval system. One thousand and eighty images of the HCFMRP-USP Database Project, Mammography Module, were used in this work. The training and test processes were realized with the "leaving-one-out" technique and the best results obtained were: The precision rate of 91,07% for the combination of the five following features group: Shape, Statistical Moments extracted of the Histogram, Moment of Hu, Statistical Moments extracted in Radon Domain and Measure of Granulometry; precision and revocation rates of the average coefficient of correlation represented by the area under the curve with value of 0,02351 for the three following features group: Shape, Haralick Textures and Moment de Hu. The results obtained indicated the relevance of our work for the content-based mammographic images retrieval.

Key-words: Content-based Image Retrieval, Mammographic Image Processing, Equation of Anisotropic Diffusion, Radon Transform, Self-Organizing Maps of Kohonen, Wiener filter, Measure of Granulometry.

Capítulo 1

Introdução

Câncer de mama é a segunda causa de mortalidade da população feminina no mundo. Nos Estados Unidos da América, estima-se que aproximadamente uma entre sete mulheres desenvolverá esta doença em algum período de sua vida.

De acordo com a American Cancer Society, descrito em ACS (2004), é esperado o aparecimento de 213.900 novos casos de câncer na população feminina dos EUA durante o ano de 2004 e a expectativa é de 40.921 mortes de mulheres por câncer de mama durante este ano. No Brasil, de acordo com o Anuário Estatístico de Saúde do Brasil – 2001, do Ministério da Saúde, o câncer de mama é a primeira causa de mortalidade na população feminina brasileira.

Os principais grupos de risco são formados por mulheres que possuem históricos familiares de câncer de mama, têm longo período de vida menstrual (menarca precoce e menopausa tardia), são obesas após a menopausa, não têm filhos ou tiveram primeira gestação tardia, fazem uso de contraceptivos ou de medicamentos de reposição hormonal, adotam dieta gordurosa, consomem bebidas alcoólicas ou são tabagistas, apresentam alta taxa de densidade fibro-glandular mamária após os 40 anos.

A mamografia é considerada a forma mais eficaz para a detecção precoce de câncer de mama, permitindo a identificação da lesão quando

ainda não é palpável (pequenos nódulos e calcificações) e, também, quando há variações de estruturas na mama (mamilo, pele retraída, distorção do parênquima, assimetria de densidade dos tecidos mamários) (Swanson, 1992). A mamografia mostra diferença nas densidades dos tecidos e esta diferença é fundamentalmente a base da imagem radiológica da mama. Os tecidos glandulares e fibrosos ou conjuntivos mais densos apresentam-se como estruturas ou regiões “claras” na mamografia (radiopaca), enquanto os tecidos adiposos, menos densos, apresentam-se cinza-claros a cinza-escuros (radioluscente), dependendo da espessura destes tecidos. Essa estrutura da mama sofre mudanças ao longo dos anos e essas mudanças são freqüentemente graduais e geralmente com a lipo-substituição dos tecidos mais densos.

1.1 Os padrões de classificação da mama de acordo com a densidade dos tecidos mamários

Estudos realizados por Wolfe (1976a, 1976b, 1976c), Moscovitz et al. (1980), relacionam a alta taxa de densidade mamária com o risco de desenvolver o câncer de mama. O risco relativo, de acordo com esses estudos, é estimado em aproximadamente 4 a 6 vezes mais alto para mamas com área relativa de densidade superior a 60% (sobre a área total da mama), comparados com mulheres que apresentam apenas 5% de densidade relativa. Esse fator de risco é considerado o mais alto entre todos os fatores.

Wolfe (1967), publicou o primeiro trabalho mostrando que estruturas encontradas na mama são características de possíveis malignidades. Ele descreveu e ilustrou os casos em que ductos com formações consideradas anormais eram indicativos para o diagnóstico de câncer de mama.

Em meados do ano de 1970, Wolfe publicou mais três trabalhos, Wolfe (1976a, 1976b, 1976c), de grande impacto na radiologia. Nestes trabalhos sugeriu que existia uma associação entre padrões do parênquima mamário e o risco de desenvolvimento de câncer de mama.

Wolfe utilizou avaliações visuais subjetivas do parênquima realizadas

por radiologistas. A classificação foi baseada na quantidade relativa de densidade dos tecidos adiposos, fibro-glandulares e ductos observados nos mamogramas considerados normais. Classificou as mamas em quatro padrões:

- N1: compreende a mama considerada normal; composta na sua maioria de tecido adiposo; é classificada como a de menor risco.
- P1: compreende a mama composta na grande maioria de tecidos adiposos; ductos proeminentes ocupam, na área subareolar, um volume igual ou menor do que 25% da mama; é classificada como de baixo risco.
- P2: compreende a mama com alto risco; os ductos proeminentes ocupam porção acima de 25% do volume da mama.
- DY: a mama contém extensa região de densidade homogênea e corresponde a mama de mais alto risco.

Nestes trabalhos, a subjetividade na classificação dos padrões da densidade mamária produziu grande variabilidade entre observadores na estimativa deste fator de risco. Desde então, diversos trabalhos foram realizados para investigar essa relação, e o método foi contestado quanto a sua exatidão por vários grupos de pesquisadores (Moskowitz et al., 1983). Porém, a premissa fundamental da relação entre a densidade do parênquima mamário e o risco de desenvolvimento de câncer permaneceu.

Outro método, atualmente, adotado pela comunidade internacional de radiologistas é o sistema BI-RADS¹ (Breast Imaging Reporting and Data System). Ele foi elaborado em 1992 pela ACR – American College of Radiology – nos Estados Unidos da América para a padronização de descrição de laudos em mamografia. O objetivo da sistematização é padronizar a nomenclatura dos laudos, que devem possuir conclusão diagnóstica e propor conduta. Ele contém várias recomendações desde a padronização de termos utilizados no diagnóstico por imagem das doenças da mama, até o enquadramento da composição do corpo mamário e dos achados mamográficos em categorias.

¹ American College of Radiology – Breast Imaging Reporting and Data system – 3rd ed. – 1992.

A avaliação da composição do tecido mamário é importante para especificar o grau de sensibilidade que se espera no diagnóstico. Quanto maior a densidade radiológica, menor a sensibilidade diagnóstica. Os casos devem ser classificados em um dos seguintes padrões:

Composição 1: as mamas são quase completamente substituídas por tecidos gordurosos.

Composição 2: Existem tecidos fibro-glandulares dispersos, que podem ocultar lesões na mamografia.

Composição 3: O tecido mamário é heterogeneamente denso. Este fato determina menor sensibilidade diagnóstica do exame.

Composição 4: O tecido mamário é extremamente denso, o que pode obscurecer uma lesão na mamografia. Este fato também determina uma baixa sensibilidade diagnóstica para o exame.

Para classificar os achados mamográficos, o padrão divide-os nas seguintes categorias:

Categoria 0: necessidade de avaliação adicional de imagem. Esta avaliação inclui incidências localizadas e magnificadas, incidências especiais, e exames de outras modalidades diagnóstica por imagem.

Categoria 1: mamografia normal ou exame negativo. As mamas são simétricas e não apresentam nódulos, distorções arquiteturais ou calcificações suspeitas.

Categoria 2: achados mamográficos benignos. Esta categoria demonstra achados mamográficos com negativos evidentes de malignidade.

Categoria 3: achados provavelmente benignos. São achados que não se espera alterações no decorrer do tempo. Por isso, são acompanhados para controle de sua estabilidade.

Categoria 4: achados suspeitos. Lesões que não têm características malignas, mas que também não podem ser classificadas como benignas. Em edições mais recentes do BI-RADS², recomenda-se subdivisão em categoria 4A (suspeita leve), 4B (suspeita moderada) e 4C (suspeita forte).

Categoria 5: altamente sugestivo de lesão maligna. Devem ser

² American College of Radiology – Breast Imaging Reporting and Data system, 4th ed.. 2003.

encaminhados para biópsia.

Em abril de 1998, o CBR – Colégio Brasileiro de Radiologia, a SBM – Sociedade Brasileira de Mastologia e FEBRASGO – Federação Brasileira de Sociedades de Ginecologia e Obstetrícia, realizaram na Jornada Paulista de Radiologia, uma reunião em que decidiram recomendar o padrão BI-RADS, como sistema ideal de padronização de laudos mamográficos.

Os padrões acima descritos mostram que a análise das estruturas de tecidos mamários é uma premissa fundamental para detecção de anormalidades na mama. A adoção de um padrão de análise dessas estruturas, mesmo que ainda dependente da subjetividade, tem melhorado a descrição de laudos e a definição de conduta na rotina médica.

Outra consideração importante é que os padrões de classificação da mama levam em consideração a evolução da mudança de tecidos ao longo do tempo. Porém, essa classificação possui alta variabilidade entre observadores (Schmidt, 1998). Neste caso, uma mesma imagem mamográfica pode ter classificação de composição diferente entre radiologistas diferentes.

1.2 Padrões de localização baseados em áreas da mama

A avaliação realizada pelo radiologista é feita dividindo a mama em regiões padronizadas e os achados radiológicos são descritos de acordo com estas regiões.

Dois padrões são comumente usados para subdividir a mama em áreas menores para fins de descrição da localização de características importantes: o sistema de quadrantes e o sistema de relógio (figura 1.1).

O sistema de quadrantes subdivide a mama em regiões tomando-se o mamilo como centro. São eles:

QSE : quadrante superior externo;

QSI : quadrante superior interno;

QIE : quadrante inferior externo;

QII : quadrante inferior interno.

O sistema de relógio compara a superfície da mama ao mostrador de

um relógio. Existem problemas neste método quando se descreve uma porção medial ou lateral da mama. A região descrita como 3:00h na mama direita deve ser descrita como 9:00h na esquerda.

A divisão da mama em regiões é feita visualmente analisando as duas incidências mamográficas.

FIGURA 1.1: Métodos do sistema de quadrantes e do relógio para descrição de informações da mama.

1.3 Incidências básicas em mamografias

As incidências de triagem básicas ou primárias realizadas em mamografia são a crânio-caudal (CC) e a médio-lateral oblíqua (MLO). Outras incidências adicionais são utilizadas quando as duas incidências básicas são insuficientes para determinar achados na mama. As incidências opcionais mais utilizadas são a médio-lateral (ML) e crânio-caudal-lateralmente-exagerada (CCLE).

Nas duas incidências básicas as estruturas mamárias são bem visualizadas. A incidência MLO oferece a melhor oportunidade de mostrar toda a mama numa única imagem. Como a mama repousa sobre o músculo peitoral, parte dele é incluída na imagem. A incidência CC oferece a presença de todo o tecido pósterio-medial. A presença do mamilo deve estar localizada na linha média perpendicular à direção da parede torácica. A figura 1.2, ilustra as duas técnicas de posicionamento para a aquisição das mamografias nas duas incidências básicas. Durante a aquisição, as mamas são comprimidas para diminuir e uniformizar a espessura da mama e

colocar as estruturas da mama o mais próximo possível do filme. Estes dois fatores melhoram a qualidade da imagem mediante menor dispersão da radiação primária.

FIGURA 1.2: Técnica de posicionamento da paciente na aquisição da imagem nas duas incidências. À esquerda, a incidência crânio-caudal (CC) e à direita, a médio-lateral-oblíqua (MLO).

1.4 Análise da mamografia pelo radiologista

O processo de análise visual das mamografias é feito basicamente em duas etapas e são utilizadas, normalmente, as quatro incidências divididas em quadrantes.

A primeira definição é composta de características estruturais da mama. O tamanho da mama e a comparação bilateral, as condições de contorno da mama e do mamilo, a distribuição dos tecidos do parênquima quanto a sua localização e a forma granular dessa distribuição, são fatores relevantes considerados durante a análise da mama.

A segunda definição é a procura de achados na região da mama e no músculo peitoral. Verificação de distorção de parênquima e detecção de lesões suspeitas do tipo nódulo ou microcalcificações, ou lesões não suspeitas como calcificações grosseiras, nódulo com contorno bem definido e outro achados, são pesquisados para a determinação da conduta a ser executada.

Todo esse processo é feito de forma visual e envolve alto grau de subjetividade. Estudos comprovam que de 10% a 30% de detecção precoce realizada por especialistas, através de análise visual, não são detectados na

rotina mamográfica (Pollei et al. 1987).

1.5 Sistema computacional de auxílio ao diagnóstico (CAD)

O Sistema computacional de auxílio ao diagnóstico (computer-aided diagnosis - CAD) surge no sentido de auxiliar o radiologista no seu trabalho de análise da mamografia (Doi, 1999).

A finalidade do CAD é melhorar a exatidão do diagnóstico, assim como a consistência da interpretação da imagem radiológica mediante o uso da resposta do computador como referência. A resposta do computador pode ser útil, uma vez que o diagnóstico do radiologista é baseado em avaliação subjetiva, estando sujeito a variações intra e interpessoais, bem como perda de informação devido à natureza sutil do achado radiológico, baixa qualidade da imagem, sobreposição de estruturas, fadiga visual ou distração. Além disso, foi demonstrado que uma dupla leitura (por dois radiologistas) pode aumentar a sensibilidade do diagnóstico (Nishikawa et al. 2000). A proposta do CAD é funcionar como um segundo especialista.

Basicamente, existem dois tipos de aplicações de sistemas CAD em mamografia. Um é o *auxílio à detecção* de lesões, a partir da localização de padrões anormais através da varredura da imagem pelo computador, por exemplo, agrupamentos de microcalcificações ou nódulo em imagens mamográficas. O outro tipo é o *auxílio ao diagnóstico*, através da quantificação de características da imagem e sua classificação como correspondendo a padrões normais ou anormais, por exemplo, forma e textura da lesão, associação da quantidade e forma das microcalcificações presentes em um agrupamento com a malignidade ou não do tumor.

Os sistemas CAD em mamografia, geralmente, são executados em duas etapas: processamento da imagem e reconhecimento de padrões. O processamento da imagem tem a finalidade de preparar a imagem para o processo de reconhecimento de padrões. Técnicas são utilizadas para retirar o ruído do fundo da imagem, realçar, segmentar e detectar regiões consideradas de interesse da imagem. A etapa de reconhecimento de padrões tem a finalidade de extrair atributos da imagem que represente

características importantes para a sua classificação. Os atributos normalmente utilizados são textura e forma.

A *textura* representa a variação da intensidade do pixel quanto à distribuição espacial na imagem (Gonzalez & Woods, 2000, 2001). Os atributos podem ser extraídos por:

- Análise estatística do histograma como a média, variância, momento de terceira e quarta ordem (skewness e kurtosis). Porém, medidas de textura calculada desta forma sofrem a limitação de não carregarem informações sobre a distribuição espacial dos pixels da imagem.

- Análise estatística da matriz de co-ocorrência utiliza uma matriz de ocorrência de intensidade de pixels vizinhos numa certa distância e direção. A partir desta matriz de ocorrência são extraídos valores estatísticos de média, variância, entropia, etc. Os mais utilizados são os atributos de textura de Haralick.

- Análise estrutural com a utilização de "primitiva de textura" e a sua distribuição e tamanho na imagem. Análise por "fractais" e de granulometria são exemplos deste tipo de atributo para análise de uma imagem.

- Análise espectral através de propriedades da frequência espacial para orientação e descrição de textura. A técnica mais utilizada é a análise de Fourier.

- Análise de Momento são utilizadas para análise de forma e distribuição da textura na imagem. Os momentos de Hu são os mais utilizados, devido as suas características invariantes à rotação, translação e escala.

A *forma* é uma representação do contorno ou fronteiras de objetos numa imagem. Podem ser descritas por descritores simples como área, diâmetro e perímetro, como por descritores mais complexos como os descritores de Fourier.

A etapa de classificação efetua a associação de atributos em classes. Essa classificação envolve a combinação de atributos para fornecer um único valor numérico indicando a sua classe. Esses atributos são apresentados aos classificadores em forma de vetores, onde os elementos

são valores numéricos representando medidas de cor, forma ou textura (Beale & Jackson, 1990). O sistema apresenta duas fases importantes: treinamento e teste.

A fase de treinamento agrupa as amostras de dados em classe e encontra a fronteira divisora que separa as classes, chamada de função discriminante. A função discriminante pode ser linear ou não linear. O treinamento pode ser supervisionado ou não supervisionado. O processo supervisionado exige a disponibilidade de um “tutor” externo que forneça ao classificador a resposta desejada para um determinado conjunto de treinamento. No treinamento não supervisionado, o sistema se auto-organiza e não existe um “tutor” externo. Não existem exemplos específicos a serem aprendidos pelo sistema. Ele deve aprender com base nas medidas dos atributos fornecidos ao classificador.

Na fase de teste, apresenta-se um conjunto de dados não utilizados no treinamento para verificar se o sistema assimilou o conhecimento e a sua capacidade de generalização.

Os principais métodos de classificação utilizados na caracterização de mamogramas variam, principalmente, entre o enfoque estatístico e determinístico, divididos em paramétrico (*Regra de Bayes*), não paramétrico (*K-vizinhos mais próximos*) e semiparamétrico (*Redes Neurais Artificiais*) (Beale & Jackson, 1990).

O sistema CAD tem objetivos bem definidos quanto ao resultado esperado, como a detecção de lesões suspeitas, a caracterização das lesões em maligna ou benigna e a análise de assimetria do parênquima mamário.

Contudo, em ambiente médico, existe a necessidade de recuperar imagens que estão armazenadas em banco de dados que apresentem características similares a uma imagem de consulta. Estes sistemas são chamados de Sistemas de recuperação de imagem baseada em conteúdo (CBIR).

1.6 Sistema de recuperação de imagem baseada em

conteúdo (CBIR)

Os sistemas CBIR normalmente utilizam também a etapa de processamento da imagem para melhoria da qualidade da imagem para extração dos atributos. Da mesma forma que os sistemas de auxílio ao diagnóstico, atributos são extraídos das imagens para representá-las. Porém, a finalidade principal é de aplicações relacionadas à semântica descritiva do conhecimento que é extraído das imagens. Esses atributos são chamados de atributos visuais.

Existem sistemas de recuperação baseada em texto que utilizam características textuais descritivas para representar as imagens (anotações, palavras-chave, características visuais de cor, textura, forma, etc). Em ambiente médico, essas características textuais estão na forma de informações gerais sobre o paciente e dados do prontuário, bem como na forma de imagens, resultantes da realização de exames (Azevedo-Marques et al., 2002).

Os sistemas extraem automaticamente os atributos visuais da imagem e armazenam essas informações juntamente com a imagem (Smeulders et al., 2000; Rui et al., 1997). Assim a recuperação baseada em conteúdo é uma alternativa importante e um complemento fundamental para os sistemas tradicionais de busca baseada em texto.

Em CBIR, as imagens são representadas também por vetores de características, que representam os atributos extraídos da imagem, da mesma forma que em sistemas CAD. Para recuperar uma imagem da base de dados, é feita uma comparação entre os atributos nos vetores de características. Essa comparação é feita por medidas de similaridade pertencentes a um espaço de métricas.

Existem várias funções que são utilizadas como medida de similaridade. As funções mais comuns são as da família L_S (ou Minkowski), definidas pela equação

$$d_s(x, y) = \left(\sum_{i=1}^k |x_i - y_i|^s \right)^{1/s} \quad (1.1)$$

onde k é a dimensão do espaço vetorial e quando $s = 1, 2, \infty$, têm-se as funções de *Manhattan*, *Euclidiana* e *Chebychev*, respectivamente.

A consulta por similaridade pode ser feita de dois modos: consulta por abrangência (*range query*) e consulta por k -vizinhos mais próximos (*k-nearest neighbor query*).

A busca por abrangência utiliza um limiar para a distância de similaridade a partir de um ponto de referência para recuperar uma imagem.

A busca por k -vizinhos mais próximo, recupera k imagens mais próximas do ponto de referência.

Observa-se que o sistema CBIR possui estrutura muito próxima dos sistemas CAD, porém o seu objetivo final é diferente. Os sistemas CBIR utilizam-se de informações como cor, textura e forma para indexação e recuperação das imagens. A busca principal é pelas imagens mais relevantes de acordo com características de similaridade entre uma imagem de consulta (*query*) e o banco de dados.

1.7 Objetivo e justificativa desta pesquisa

Câncer de mama ainda é a principal causa de morbidade e mortalidade da população feminina mundial, apesar da melhoria da detecção precoce dessa doença. A detecção precoce, através de análise minuciosa das estruturas que compõem a mama, tem sido alvo de cuidados por parte de médicos e especialistas, principalmente a análise da densidade presente na mamografia. O padrão de Wolfe e o BI-RADS são exemplos da necessidade de cuidados especiais da análise da estrutura dos tecidos mamários e sua evolução ao longo do tempo. Porém, a análise visual realizada por radiologistas especialistas contém alto grau de subjetividade. Com o objetivo de auxiliar os radiologistas nesta tarefa de análise, vários trabalhos têm sido apresentados, propondo métodos automáticos, na maioria em sistemas CAD, para auxílio ao diagnóstico.

Em sistemas de recuperação de imagens mamográficas baseada em conteúdo (CBIR), não existe qualquer trabalho apresentado até o momento que realize a busca de imagens por similaridade de densidade radiológica da mama.

O objetivo principal desta pesquisa foi investigar atributos visuais para a recuperação de imagens mamográficas baseada em conteúdo (CBIR). Atributos que caracterizem a densidade mamária correspondente às estruturas de tecidos fibro-glandulares da mama, levando em consideração a sua distribuição e forma. A pesquisa consiste de três etapas:

- Preparar e processar as imagens com técnicas para retirada de ruído, segmentação da região da mama, detecção automática da linha que separa a região do músculo peitoral em imagens da incidência MLO, detecção automática da posição do mamilo e segmentação da região de tecido fibro-glandular da mama.
- Extrair atributos visuais de forma e textura. Os atributos de textura terão abordagem estatística de histograma, estatística de matriz de co-ocorrência, estrutural, espectral e de momento.
- Implementar um classificador através de rede mapa auto-

organizável de Kohonen (SOM) como sistema de recuperação de imagem a partir dos atributos visuais de treinamento e consulta.

A proposta indicada levou em consideração todas as etapas de um CBIR para recuperar imagens de acordo com atributos que caracterizem as estruturas dos tecidos e sua distribuição na região da mama. A única exceção foi a não implementação de uma estrutura de indexação de busca das imagens na base de dados. A figura 1.3 apresenta o diagrama de blocos da metodologia deste trabalho.

A primeira etapa foi necessária devido às condições em que as imagens foram apresentadas ao sistema. As presenças de artefatos e identificadores (dados da paciente e da incidência da mama), exigiram a preparação das imagens antes do início de seu processamento. A figura 1.4 apresenta o diagrama de blocos desta etapa.

As imagens utilizadas apresentaram-se extremamente ruidosas, interferindo na localização da borda e do mamilo. A aplicação de uma técnica adequada de retirada de ruído e restauração da borda foi necessária na etapa de pré-processamento.

Durante a análise visual realizada por radiologista na mamografia, algumas regiões da mama têm grande importância diagnóstica: o contorno da mama, incluindo o mamilo, a região de músculo peitoral na incidência MLO e a região efetiva da mama, composta principalmente de tecidos fibroglandulares e adiposos.

Para os sistemas computacionais de análise e medidas de densidade mamária estas regiões têm também grande importância. Os atributos para análise e detecção (lesões e densidade) são comumente extraídos desta região ou de sub-regiões de interesse. A região de músculo peitoral, presente na incidência médio-lateral oblíqua, é normalmente identificada e recortada da região da mama devido às suas características de alta densidade radiológica que afetam de modo significativo os resultados dos algoritmos de processamento da imagem e reconhecimento de padrões (Ferrari, 2004). Em nosso trabalho, a identificação da linha da região do músculo peitoral, foi primordial para definição da região de interesse e

alinhamento das mamas de incidência MLO. A detecção do mamilo, em nosso trabalho, foi importante para a determinação das regiões de interesse e o alinhamento entre as imagens das mamas das duas incidências (CC e MLO). A segmentação da região fibro-glandular permitiu a determinação de regiões de interesse para extração de atributos.

Como foi frisado anteriormente, o objetivo principal do trabalho foi investigar atributos que melhor caracterizem a estrutura de densidade da mama em um sistema de recuperação de imagem. Experiências anteriores mostraram a alta taxa de discriminação de atributos de textura e forma em sistemas CAD (Kinoshita et al., 1999, 2000; El-Faramawy et al., 1996; Pohlman et al., 1996; Petrosian et al., 1994). Para sistemas CBIR, esses atributos com o objetivo proposto neste trabalho, não foram ainda investigadas. Foram investigados, também, novos atributos de textura com abordagem espectral no domínio de Radon e estrutural através de medida de Granulometria. Esses atributos são inéditos, até o momento, em análise de imagens mamográficas. Nesta etapa, são feitas a extração e seleção de atributos visando prepará-las para a próxima etapa. A figura 1.5 apresenta o diagrama de blocos desta etapa.

A escolha de um sistema que atenda as características de um CBIR é fundamental. A escolha recaiu para a rede neural de mapa auto-organizável de Kohonen devido ao alto desempenho em classificação não supervisionada. A utilização da rede SOM como sistema CBIR foi apresentada por Laskonen et al. (2000,2001) para recuperação de imagens de vários tipos. O sistema foi chamado de PicSOM e é baseado em estrutura em árvore de atributos de cor, textura e forma. A figura 1.6 apresenta o diagrama de blocos desta etapa.

FIGURA 1.4: Diagrama de Blocos do Geral da Metodologia

FIGURA 1.4: Diagrama de blocos da etapa de preparação e processamento da imagem

FIGURA 1.5: Diagrama de bloco da etapa de extração e seleção de atributos.

FIGURA 1.6: Diagrama de blocos da etapa de classificação e comparação por similaridade.

1.8 Organização da tese

A tese está organizada em 10 capítulos e as referências bibliográficas, contando esta introdução. Apresentamos, a seguir, além deste capítulo de Introdução, uma descrição resumida de cada capítulo.

- Capítulo 2: apresenta uma revisão bibliográfica sobre métodos de sistemas CBIR e CAD em mamogramas digitalizados.
- Capítulo 3: apresenta a base de imagens utilizada, preparação das imagens e os sistemas e programas utilizados.
- Capítulo 4: apresenta as técnicas para retirada de ruído e restauração da borda da mama.
- Capítulo 5: apresenta as técnicas aplicadas para a segmentação da região da mama.
- Capítulo 6: apresenta as técnicas para detecção da região do músculo peitoral e do mamilo, e de segmentação da região fibroglandular.
- Capítulo 7: apresenta os atributos visuais utilizados para caracterização dos tecidos da mama.
- Capítulo 8: apresenta o método de seleção de atributos, a rede neural auto-organizável de Kohonen para recuperação de imagem e o método de comparação por similaridade.
- Capítulo 9: apresenta os resultados e a discussão sobre cada etapa do trabalho.
- Capítulo 10: apresenta as conclusões do trabalho.
- Apêndice
- Referências bibliográficas.

Capítulo 2

Revisão Bibliográfica

É apresentada, neste capítulo, uma breve descrição de trabalhos de sistema de recuperação de imagem baseado em conteúdo (CBIR) em imagens mamográficas e sistemas computadorizados de auxílio ao diagnóstico (CAD). São apresentados, também, trabalhos que tratam das imagens antes do processo de extração de atributos e classificação nos sistemas CAD.

2.1 Análise de densidade mamária em sistema CBIR

El-Naqa et al. (2002a, 2002b) exploraram o uso de uma estrutura baseada em aprendizagem para a recuperação de imagens mamográficas relevantes de uma base de imagens. Investigaram o uso de redes neurais e a técnica Support Vector Machine (SVM) numa aprendizagem hierárquica, em dois estágios, para prever a similaridade perceptual obtida com a coletada através de observação humana. A proposta foi validada usando conjunto de imagens com microcalcificações extraídas de uma base de dados com 76 mamogramas.

Azevedo-Marques et al. (2002) desenvolveram um sistema de recuperação de imagens mamográficas para o auxílio ao diagnóstico. A proposta utiliza atributos visuais de textura de Haralick para caracterizar microcalcificações em regiões de interesse da imagem. O sistema recupera imagens similares que possuem regiões de interesse com as mesmas

características da imagem de consulta.

Honda et al. (2002) utilizaram atributos de textura de Haralick para minimização do “gap” semântico em sistemas CBIR para imagens mamográficas. O sistema visa o auxílio ao diagnóstico de lesões da mama por inspeção visual (comparação visual entre a imagem investigada e imagens previamente classificadas e seus laudos). Busca também a correlação com as imagens recuperadas (atributos de baixo nível) com seu significado semântico (atributos de alto-nível). As imagens foram classificadas segundo o padrão BI-RADS.

Santos André et al. (2004) apresentaram proposta de utilização de rede neural de mapa auto-organizável e correlação cruzada para recuperação de imagens mamográficas. As imagens são representadas por vetores de atributos do tipo mosaicos extraídos da imagem. Esses mosaicos são construídos a partir da classificação da rede SOM de regiões de pixels representando a densidade dos tecidos (1-4), o tamanho da mama, lado da mama (esquerdo ou direito), e a forma da mama (circular ou elíptica). A recuperação das imagens é feita de acordo com a correlação entre a imagem de consulta e as imagens da base de dados pela medida de correlação cruzada.

2.2 Análise de densidade mamária em sistema CAD

Zhou et al. (2001) propuseram a análise da densidade mamária através de atributos extraídos do histograma de nível de cinza de acordo com picos correspondendo aos tecidos adiposos e fibro-glandulares. A classificação da densidade foi realizada dentro do padrão BI-RADS.

Saha et al. (2001) desenvolveram um método para a análise de densidade mamária, utilizando o método de “scale-based fuzzy connectedness” para separar regiões de interesse das imagens. Os *pixels* foram classificados de acordo com um parâmetro de afinidade e desta forma faziam parte das classes que correspondiam às regiões do fundo do filme, região de tecido fibro-glandular, adiposo e de músculo peitoral.

Huo et al. (2000) propuseram o estudo de 14 atributos para identificar

padrões do parênquima mamário. Esses atributos foram agrupados em: (i) atributos baseados nos valores absolutos do nível de cinza; (ii) atributos baseados na análise do histograma; (iii) atributos baseados na relação espacial entre os níveis de cinza dentro de uma região de interesse; e (iv) atributos baseados na transformada de Fourier.

Karssemeijer (1998) publicou proposta de classificação automática de densidade mamária usando um conjunto de atributos extraídos de histogramas gerados a partir de um mapa de pixels em diferentes distâncias entre a parede torácica e a linha da superfície da mama. Do histograma, foi calculado o desvio-padrão e o atributo de skewness que variou inversamente com a densidade do parênquima. Mais dois atributos foram extraídos, tomando-se a diferença de brilho entre os tecidos que compõem a região da mama (tecido adiposo e fibro-glandular) e o tecido do músculo peitoral. Foram determinadas probabilidades de densidade das duas regiões e calculados dois atributos: um medindo a diferença da média das duas distribuições e o outro a diferença entre as distribuições de forma geral.

Tahoces et al. (1995) propuseram atributos extraídos de regiões de interesse da região da mama divididos em três grupos de atributos. No primeiro grupo foi obtida a variação da raiz quadrada da média, primeiro e segundo momento do espectro de potência da transformada de Fourier. No segundo grupo, foram extraídos: contraste, aspereza (coarseness), taxa de ocupação (busyness), complexidade (complexity) e energia (strength). No terceiro grupo, foram extraídos 4 valores limiares (threshold), obtidos pela variação de valores de máximo, mínimo e valores normalizados de nível de cinza. A análise utilizou o critério de Wolfe para classificação da densidade da mama.

Cadwell et al (1990) apresentaram uma investigação sobre o uso da dimensão fractal para classificação da densidade mamária de acordo com o critério de Wolfe.

Byng et al. (1996), propuseram também a utilização da dimensão fractal e o parâmetro do skewness como atributos para classificação de densidade mamária.

2.3 Preparação da imagem e processamento de imagem

2.3.1 Tratamento de ruídos em mamogramas digitalizados

Foram encontrados poucos trabalhos que explicitam de modo claro e preciso o tratamento do ruído realizado na etapa de pré-processamento das imagens mamográficas. Deve-se a isso, a baixa taxa de ruídos presentes nas imagens em geral, e o foco principal dedicado à detecção ou análise de lesões presentes na mamografia.

Lai et al. (1989) utilizaram o filtro mediano modificado, chamado de filtro mediano seletivo (SMF). O algoritmo proposto seleciona o pixel mediano quando a diferença entre o pixel central e sua vizinhança é menor que um limiar adotado (T). Se o limiar T adotado tem valor pequeno, a suavização efetiva será baixa; se, caso contrário, for adotado um valor grande de T , haverá uma alta suavização. Ajustando o valor de T , a preservação da borda pode ser ajustada.

Sersic & Loncaric (1998) aplicaram a transformada Wavelet para a detecção de microcalcificações. Eles realizaram a decomposição das imagens em 5 níveis: o nível 1, responsável pela maior parte do ruído presente na imagem foi suprimido, e os níveis 2 e 3, representativos das microcalcificações, foram submetidos a uma filtragem denominada "soft thresholding", onde o limiar utilizado é proporcional ao logaritmo dos coeficientes Wavelet e ao desvio padrão do ruído nas imagens.

2.3.2 Segmentação automática da região da mama

Yin et al. (1994), Kassemeyer (1998), te Brake et al. (2000), Sallam & Bowyer (1999), e Sivaramakrishna et al. (2001) utilizaram o método de limiarização e análise de histograma para segmentar a região da mama. Algoritmos de detecções automáticas de picos e vales do histograma foram utilizados. Yin et al. (1994) segmentaram a região da mama para alinhamento bilateral. Eles executaram a técnica de subtração bilateral para detecção automática de nódulos. Eles aplicaram operações de filtragem morfológica para suavização da imagem antes da segmentação. Kassemeyer (1998) segmentou a região da mama para classificação do

parênquima mamário. O mesmo algoritmo foi utilizado por te Brake et al. (2000) para discriminar nódulos de tecidos normais em mamogramas digitalizados. Sallam & Bowyer (1999) segmentaram a região da mama para registro e análise de diferença bilateral entre os mamogramas. Sivaramakrishna et al. (2001) apresentaram o trabalho de segmentação da região de tecidos fibro-glandulares da mama.

Méndez et al. (1996) propuseram técnica de detecção do contorno da mama usando a variação de nível de cinza entre a região da mama e o fundo da imagem. Eles criaram primeiramente uma imagem suavizada com o filtro da média e analisaram a irregularidade de nível de cinza ao longo de direções verticais e horizontais. O valor de intensidade de pixel da região pertencente à mama (região exposta à radiação) é maior do que a do fundo da imagem (região não exposta à radiação).

Ferrari et al. (2000) segmentaram a imagem através do algoritmo "Lloyd-Max Least-Square" desenvolvido por Lloyd (1982) que é uma técnica iterativa para projeto de quantizadores com baixa distorção. Essa técnica usa informação do histograma para otimizar o procedimento de quantização aplicada à imagem, avaliando cada possibilidade de quantização e determinando qual possui menor distorção. A área segmentada serviu para detectar a região anatômica da mama caracterizada pela presença de tecidos densos nomeada como disco fibro-glandular.

Zhou et al. (2001) utilizaram o método baseado em gradiente para pesquisar os pontos da borda da mama. O fundo da imagem foi estimado inicialmente através da identificação de maior pico no histograma em nível de cinza correspondente aos pixels de fundo da imagem. Após a subtração do nível de fundo da imagem, a borda foi encontrada através de análise de gradiente linha a linha do topo à base da imagem.

A técnica de contorno ativo para detecção automática do contorno da região da mama foi proposta nos trabalhos realizados por Ferrari (2002), Ojala et al. (2001) e Wirth & Stapinski (2003). Primeiramente, um contorno inicial é detectado e através de amostragem um conjunto de pontos desse contorno é selecionado. O contorno amostrado é movido no domínio

espacial de maneira a minimizar uma função de energia. Essa função de energia é formada pela energia interna e externa. A energia interna possui um termo de continuidade e um termo de expansão em direção à borda. A energia externa utiliza informações de magnitude e direção do gradiente da imagem e visa atrair o contorno para a borda da mama. Ferrari (2002) usou o método de limiarização através do algoritmo "Lloyd-Max least-square" (Lloyd, 1982) para determinar o contorno inicial. Ojala et al. (2001) utilizaram limiarização com a análise de histograma. Wirth & Stapinski (2003) usaram o algoritmo de limiarização proposto por Rosin (2001) para determinar os pontos que compõem a borda da mama. Através do método de mínimos quadrados, foi obtida a curva interpolada do contorno da região da mama.

Saha et al. (2001) usaram a conectividade fuzzy baseada escala (scale-based fuzzy connectivity) para segmentar a região da mama. Bick et al. (1995) propuseram a classificação de pixels baseada na faixa de intensidade local para segmentar a região da mama combinada com a técnica de crescimento de região e morfologia matemática. Heine et al. (1998) aplicaram uma expansão wavelet multiresolução para separar a região da mama do fundo da imagem.

2.3.3 Detecção automática da linha da região do músculo peitoral

Pesquisadores realizaram a detecção automática do músculo peitoral utilizando técnicas voltadas a limiarização (Sallam & Bowyer, 1999), detecção de linhas retas (Kassemeijer, 1998; Ferrari et al., 2000; Ferrari, 2002; Ferrari et al., 2004; Zhou et al., 2001) ou por técnicas de análise direcional (Ferrari, 2000; Ferrari et al., 2004).

Kassemeijer (1998) usou a transformada de Hough e um grupo de limiares aplicados ao arranjo acumulador para detectar o músculo peitoral. Uma região de interesse contendo o músculo peitoral é adotada, tomando-se o centro de massa da imagem e uma linha reta com uma certa declividade. Os pixels acima desta linha formaram a região de interesse. Dentro desta região, ele aplicou o operador de Sobel para obter a imagem gradiente.

Nesta imagem gradiente o contorno do peitoral foi detectado pelo valor de máximo gradiente. A transformada de Hough foi executada para detectar esse contorno.

Ferrari et al. (2000, 2002, 2004) aplicaram também a transformada de Hough e uma região de interesse diferente à adotada por Kassemeyer (1998). Em trabalhos posteriores, eles detectaram a região de músculo peitoral através de análise direcional com filtros de Gabor. Determinaram primeiramente uma região de interesse (ROI) contendo a região de músculo peitoral. A seguir, realizaram a decomposição da ROI em componentes direcionais (magnitude e fase) através da convolução da ROI com os filtros de Gabor e a aplicação da transformada de Karhunen-Loève.

Yam et al. (2001) utilizaram também a transformada de Hough como em Kassemeyer (1998) para determinar a linha de músculo peitoral. Após essa determinação, eles refinaram a segmentação detectando o contorno exato da região do músculo peitoral através de um método dinâmico proposto por Hayton (1998) que detecta linhas curvas.

Sallam & Bowyer (1999) utilizaram a limiarização, filtros morfológicos de erosão e dilatação, e processos de elementos conectados. A limiarização foi feita por análise de histograma. Detectada a região do músculo peitoral, operadores de morfologia matemática com elemento estruturante com formato apropriado foram aplicados para preservar a forma dessa região. O algoritmo de componentes conectados foi utilizado para identificar a região dentro do mamograma.

Zhou et al. (2001) utilizaram a imagem gradiente para detectar a borda da região do músculo peitoral da mesma forma que Kassemeyer (1998). Uma linha reta foi definida com os pontos detectados anteriormente. Os pontos (pixels) não pertencentes a essa linha foram descartados e os pontos positivos são conectados.

As avaliações do processo de detecção da região de músculo peitoral encontrados na literatura variam entre inspeções visuais simples realizados por especialistas (Kassemeyer, 1998), ou por avaliações comparativas com o traçado manual realizados por especialistas (Ferrari et al., 2004; Zhou et

al., 2001). Em alguns trabalhos, a avaliação é omitida por não participar do enfoque principal do trabalho (Ojala et al., 2001; Sallam & Bowyer, 1999; Yam et al., 2001). Em nosso trabalho, utilizamos um método quantitativo baseado na comparação com o traçado realizado por um especialista.

2.3.4 Detecção automática do mamilo

Há relativamente poucos trabalhos na literatura de localização do mamilo em mamogramas digitalizados. O primeiro trabalho, que discutiu esse problema, foi feito em xeromamograma por Semmlow et al. (1980). Eles usaram um filtro espacial sensível à forma para gerar medida de aspereza e direção para detectar a borda da mama. O ponto de maior variação desta medida na borda da mama, foi considerado como a posição do mamilo.

Yin et al. (1994) detectaram o mamilo como parte da técnica de subtração bilateral. Eles extraíram a borda da mama e calcularam a média de nível de cinza em pequenas regiões (10x40 pixels) ao longo da borda. Então, plotaram a intensidade média relativa em relação à posição na borda e identificaram o mamilo pelo máximo valor na curva.

Méndez et al. (1996) apresentaram um algoritmo para identificar o mamilo. Primeiro, dividiram a mama em três regiões: uma região central e duas laterais. A seguir, o algoritmo identificou as máximas alturas da borda na região central da mama como prováveis posições do mamilo. Para confirmação desta hipótese, eles calcularam a primeira derivada desta região ao longo de linhas retas a partir de um ponto central de referência dentro desta região. A análise de gradiente identificou os limites do contorno da mama. Identificado o contorno, foi calculada a segunda derivada ao longo desta mesma região por análise de gradiente. Determinaram-se também posições prováveis do mamilo ao longo do contorno da mama. A combinação destas duas hipóteses, localizou a posição do mamilo.

Chandrasekhar & Attikiouzel (1997) utilizaram o gradiente médio de intensidade na direção normal da interface pele-ar, onde houve uma súbita mudança neste parâmetro próximo ao mamilo. Eles analisaram o caso de

mamografias que apresentaram o mamilo em destaque e sem destaque. A análise de gradiente e as derivadas deste parâmetro determinaram a localização do mamilo.

2.3.5 Segmentação da região fibro-glandular em mamografia

Ferrari et al. (2000) detectaram a região mais densa da mama através da técnica de “máxima probabilidade”. O método usou a informação da intensidade de níveis de cinza para estimar um modelo estatístico representando os tecidos adiposos e fibro-glandulares da imagem. O modelo usado na técnica de segmentação é o modelo da “mistura de Gaussianas” sendo seus parâmetros estimados pelo algoritmo EM (Expectation-Maximization).

Saha et al. (2001) utilizaram a estratégia de lógica nebulosa para segmentar a região densa da mama. Eles definiram os pixels da região da mama com um conjunto de objetos nebulosos conectados (fuzzy connected objects). A região adiposa foi definida indiretamente como o complemento da região densa na mama. Um conjunto de pixels foi classificado de acordo com um parâmetro de afinidade nebulosa (affinity fuzzy). O valor de limiar foi definido pela minimização de uma função de energia computada dentro de sub-regiões da mama. Um limiar dividiu a cena em duas sub-regiões. Uma estatística de segunda ordem foi aplicada para retirar da cena pixels discordantes.

Sivaramakrishna et al. (2001) aplicaram o método de limiarização. Eles inicialmente aplicaram um filtro para suprimir linhas finas que correspondiam aos ligamentos de Cooper, vasos sanguíneos e dutos que consideraram prejudiciais ao processo de identificação de tecidos fibro-glandulares. A seguir aplicaram a limiarização, conseguindo uma imagem com predominância de tecidos glandulares.

Capítulo 3

Base de dados, preparação das imagens e programas utilizados

As imagens utilizadas neste trabalho de pesquisa pertencem ao projeto de Banco de Imagens do HCFMRP-USP, módulo Mamografia, processo HCRP número 10093/2003. Foram selecionados 270 casos de pacientes com os respectivos laudos. Isto corresponde a 1080 mamografias distribuídas em 270 mamografias bilaterais da vista crânio-caudal (CC) e 270 mamografias bilaterais da médio-lateral-oblíqua (MLO). Os laudos foram realizados por especialistas do setor de radiodiagnóstico do Centro de Ciências das Imagens e Física Médica (CCIFM), pertencente ao departamento de Clínica Médica (DCM) da Faculdade de Medicina de Ribeirão Preto (FMRP-USP). Nos laudos, constam descrições de características análise de simetria, classificação volumétrica da mama, distribuição da densidade e, em caso de características suspeitas, os tipos e localizações das lesões. Assinalam, também, a discriminação da mama pela composição dos tecidos (1, 2, 3 e 4) e categoria (0, 1, 2, 3 e 4) de acordo com o critério do BI-RADS. A tabela 3.1 apresenta a distribuição dos casos selecionados de acordo com a composição dos tecidos mamários.

TABELA 3.1: Distribuição dos casos selecionados de pacientes de acordo com a composição dos tecidos mamários classificados pelo critério do BI-RADS.

Incidência	Composição por BI-RADS				Total
	1	2	3	4	
CCD	90	112	50	18	270
CCE	91	111	50	18	270
MLOD	90	112	50	18	270
MLOE	91	111	50	18	270
Total	362	446	200	72	1080

CCD: crânio-caudal-direita; CCE: crânio-caudal-esquerda;
MLOD: médio-lateral-oblíqua direita; MLOE: médio-lateral-oblíqua esquerda

3.1 Digitalização dos filmes mamográficos

Os filmes mamográficos utilizados nos serviços de radiologia variam de tamanho de acordo com as dimensões da mama. Para mamas consideradas de grandes dimensões são utilizados filmes de 24x30 cm e para dimensões menores utilizam-se filmes de 18x24 cm. Dos casos selecionados 37 foram processados em filmes de dimensão maior e 233 nos filmes de dimensão menor.

As mamografias foram digitalizadas em um equipamento scanner da marca Vidar modelo DiagnóscicPro com resolução espacial de 300 dpi (tamanho aproximado de *pixel* de 84,67µm) e 12 bits de quantização (4096 níveis de cinza). As imagens digitalizadas, de acordo com as dimensões das mamografias, possuíam matrizes com dimensões aproximadas de 2835x3543 pixels e 2126x2835 pixels.

3.2 Recorte da imagem mamográfica digitalizada

Para retirar a identificação da paciente registrada no filme, foram feitos recortes nas imagens digitalizadas. Elas passaram a ter resoluções espaciais de 2400x3380 pixels e 1810x2700 pixels de acordo com a dimensão do filme mamográfico. Para diminuir o custo computacional, as imagens digitalizadas foram redimensionadas para uma resolução espacial de 1024x1024 pixels.

Para obter a imagem com essa nova dimensão escalar e manter a razão de aspecto da imagem, evitando, com isso, distorções causadas pela transformação, foram mantidas a largura da imagem anterior e foi acrescentada, em cada lado da imagem, uma matriz retangular com pixels com valor de fundo preto de tal forma que a matriz da imagem passasse a ter o mesmo número de pixels. A imagem resultante obtida com essa transformação passou a ter dimensão 3380x3380 pixels ou 2700x2700 pixels dependendo do tamanho da imagem de origem. A seguir, a imagem foi redimensionada para 1024x1024 pixels aplicando interpolação bilinear. A figura 3.1 mostra uma seqüência das transformações escalares realizadas para obter uma imagem de 1024x1024 pixels.

A figura 3.2 mostra uma imagem original e a imagem após o recorte e a transformação de sua resolução espacial. Com essa transformação o novo tamanho aproximado do pixel passou de 84,67 μ m para 223,50 μ m e 279,40 μ m dependendo do tamanho do filme utilizado. Esta referência será importante para a avaliação de medidas espaciais na imagem (erro da posição do mamilo e da linha de separação do músculo peitoral) que serão realizadas em nosso trabalho. Para saber a distância em μ m de um ponto a outro da imagem, basta multiplicar a distância em pixel pelo seu tamanho.

3.3 Programas utilizados

Os algoritmos desenvolvidos neste trabalho foram executados em um computador Pentium 4, 2.0 GHz, 256MB DDR e monitor 17". Eles foram desenvolvidos em MatLab® Language of Technical Computing, versão 6.5 Release 13, para sistema operacional Windows-XP Pro da Microsoft® Inc. Foi usado o algoritmo de difusão anisotrópica de domínio público da biblioteca disponível em:

<http://www.csse.uwa.edu.au/~pk/Research/MatlabFns/index.html>.

FIGURA 3.1: Transformação escalar das imagens. Na primeira coluna, é ilustrado o recorte realizado na imagem (cinza mais claro) para retirada da identificação da paciente (cinza escuro). Na coluna do meio é feito o acréscimo de uma matriz de pixels nos dois lados da imagem para obter uma imagem de matriz quadrada. Na coluna mais à direita a imagem é redimensionada para 1024x1024 pixels.

FIGURA 3.2: Transformação de resolução espacial da imagem. Em (a), a imagem original possui matriz de 2126x2835 pixels. Em (b), a imagem possui matriz de 1024x1024 pixels após a transformação de recorte e redimensionamento com interpolação bi-linear.

Capítulo 4

Pré-processamentos das imagens para retirada de ruídos e recuperação da borda da região da mama em mamogramas digitalizados.

Uma imagem mamográfica pode ser degradada durante os processos de aquisição, transmissão ou digitalização da imagem. Uma das causas de degradação da imagem é a adição de ruído durante a aquisição ou digitalização da radiografia. Pode ocorrer, também, a geração de borramento devido ao movimento da imagem ou à falhas da processadora do filme durante a geração da mamografia ou na aquisição digital da imagem. A restauração é uma técnica de correção ou redução da degradação da imagem ocorrida durante esses processos. A correção é feita por filtros lineares ou não lineares especializados para cada tipo de degradação encontrada na imagem (Gonzalez & Woods, 2000, 2001).

A remoção de ruídos em imagens mamográficas é importante, pois ele interfere nas etapas de processamento da imagem e na extração de atributos para análise e classificação.

As imagens selecionadas do acervo do HCFMRP-USP apresentavam altos níveis de ruídos. Provavelmente, essa degradação ocorreu durante o processamento automático de revelação da mamografia realizada pela processadora do filme. Por causa disso, uma etapa de pré-processamento de imagem foi necessária para restauração, principalmente, da borda da

região da mama e de estruturas importantes como o mamilo. Para isso, o método proposto foi o de Difusão Anisotrópica com pré-filtragem com o filtro de Wiener.

4.1 Equação de Difusão Anisotrópica

A equação de difusão anisotrópica original permite a suavização seletiva de uma imagem. Preserva o contraste em regiões do contorno da imagem dentro de uma operação adaptativa, e promove a suavização intra-região enquanto inibe interações inter-regiões. Porém, não garante a remoção de detalhes de pequena escala e de alto contraste, características típicas dos ruídos.

Perona & Malik (1990) foram pioneiros na utilização dessa equação em imagens digitalizadas. O objetivo da equação de Difusão Anisotrópica de Perona-Malik, como é conhecida, é garantir que o gradiente de difusão mude de acordo com o gradiente local da imagem, e crie um filtro capaz de suavizar localmente a região da imagem, enquanto tende a manter a borda da imagem. Para isso, a equação de Difusão Anisotrópica objetiva tornar um pixel da imagem mais próximo de seus vizinhos por uma medida de similaridade. A equação é dada por:

$$\frac{\partial I}{\partial t} = \text{div}[c \nabla I] \quad (4.1)$$

onde **div** é o operador divergente, ∇I é a imagem gradiente, e **c** é o coeficiente de difusão. Com isso, o coeficiente de difusão muda de acordo com o gradiente local da imagem e atua como função de similaridade para o critério de avaliação do gradiente.

A implementação original do coeficiente de difusão anisotrópica depende unicamente da informação do gradiente local, e é dado por:

$$c = \exp\left(-\left(\frac{\|\nabla I\|}{k}\right)^2\right) \quad (4.2)$$

onde, **c** é o coeficiente de difusão e **k** é um gradiente limiar.

A primeira sugestão de alteração no coeficiente de difusão foi

formulada por Catté et al. (1992). O objetivo da proposta foi resolver o problema de retirada do ruído aplicando uma pré-filtragem com o filtro Gaussiano antes da aplicação da equação de Difusão Anisotrópica de Perona-Malik. A fórmula do coeficiente de difusão ficou alterada da seguinte forma:

$$c = \exp\left(-\frac{\|\nabla(Go * I)\|}{k}\right)^2 \quad (4.3)$$

onde, $(Go * I)$ é a operação de convolução de um filtro passa-baixa Gaussiano com a imagem I , e k é o gradiente limiar. Essa pré-filtragem do gradiente, despertou a atrativa idéia de remoção de pequenas regiões e com alto contraste.

Neste mesmo sentido, Segall e Acton (1998) propuseram um coeficiente de difusão com capacidade de suavização de objetos de pequena escala e com características de minimização de deslocamento de informações de borda encontradas na formulação dada por Catté et al (1992a, 1992b). Eles aplicaram filtros não lineares baseados em operadores morfológicos. Da mesma forma, propuseram uma alteração no cálculo do coeficiente de difusão anisotrópica de Perona-Malik:

$$c = \exp\left(-\frac{\|\nabla((I \bullet S) \circ S)\|}{k}\right)^2 \quad (4.4)$$

onde I é a imagem original, k é limiar de gradiente, $((I \bullet S) \circ S)$ é a operação morfológica de fechamento e abertura, respectivamente, com elemento estruturante S (Gonzalez & Woods, 2000, 2001),

4.2 Equação de Difusão Anisotrópica com filtro de Wiener

A aplicação da equação de Difusão Anisotrópica com a pré-filtragem morfológica não apresentou resultados esperados de restauração das imagens mamográficas utilizadas. Foi verificado que em algumas imagens, informações de borda e do mamilo não foram adequadamente restauradas. Foi aplicada, então, a pré-filtragem com filtro gaussiano, proposta por Catté

et al. (1992a, 1992b), e a pré-filtragem utilizando o filtro adaptativo de Wiener. A escolha do filtro de Wiener se deve às suas características conhecidas de retirada de ruído e de redução de borramento da imagem (Jain, 1989).

O filtro adaptativo de Wiener suaviza uma imagem que foi degradada por ruído aditivo. A imagem possui propriedades que não são estacionárias e mudam ao longo da imagem. O filtro adaptativo atua localmente assumindo que o sinal é estacionário em pequenas regiões da imagem. O algoritmo é executado na seguinte sequência:

Etapla 1: estima-se localmente nas vizinhanças de cada pixel (p) a média (μ) e a variância (σ^2), através de:

$$\mu = \frac{1}{NM} \cdot \sum_{n_1, n_2 \in \eta} p(n_1, n_2) \quad (4.5)$$

$$\sigma^2 = \frac{1}{NM} \cdot \sum_{n_1, n_2 \in \eta} (p^2(n_1, n_2) - \mu^2) \quad (4.6)$$

onde η é a vizinhança local $N \times M$ de cada pixel na imagem.

Etapla 2: calcula-se, então, a partir da estimativa dada na etapa 1, o novo valor (p') do pixel (p) em relação à sua vizinhança:

$$p'(n_1, n_2) = \mu + \frac{\sigma^2 - \sigma_r^2}{\sigma^2} \cdot (p(n_1, n_2) - \mu) \quad (4.7)$$

onde σ_r^2 é a variância do ruído, que é calculada usando a média de todas variâncias locais estimadas do ruído.

A figura 4.1, apresenta uma comparação entre a aplicação da equação de difusão anisotrópica de Perona-Malik com os filtros Gaussiano, Morfológico e de Wiener. O filtro Gaussiano foi aplicado com tamanho de janela igual a 11 pixels e desvio-padrão igual a 1. O filtro morfológico foi aplicado com a operação de fechamento e abertura com elemento estruturante em forma de disco com raio igual a 5 pixels. O filtro adaptativo de Weiner foi aplicado com tamanho de janela igual a 11 pixels.

FIGURA 4.1: Ilustra a aplicação da equação de difusão anisotrópica com pré-filtragem. Em (a) a imagem original ruidosa, em (b) aplicado filtro gaussiano, em (c) aplicado o filtro morfológico e em (d) o filtro de Wiener.

4.3 Avaliação dos processos de suavização do ruído e restauração da borda da região da mama

A avaliação do método utilizado para a suavização do ruído foi realizada através da relação do sinal-ruído média quadrática (SNR), dada pela equação (Gonzalez & Woods, 2000, 2001):

$$SNR = 10 \cdot \log \left[\frac{\sum_{x=0}^{M-1} \sum_{y=0}^{N-1} \hat{f}(x, y)^2}{\sum_{x=0}^{M-1} \sum_{y=0}^{N-1} [\hat{f}(x, y) - f(x, y)]^2} \right] \quad (4.7)$$

Onde, f representa a imagem original, e $\hat{f}$ a imagem após a retirada do ruído. O resultado da equação é dada em decibéis (dB). Foi calculada a média sobre as imagens para cada incidência (CCD, CCE, MLOD e MLOE) e de todas as incidências em conjunto.

Capítulo 5

Segmentação da região da mama em mamogramas digitalizados.

A mamografia contém duas regiões distintas: a região exposta à radiação correspondente aos tecidos da mama, e a região não exposta à radiação correspondente ao fundo da mamografia. Entre essas duas regiões, existe uma região de interface pele-ar que define o contorno da mama. Portanto, o contorno da mama pode ser obtido pela determinação desta região na mamografia. Essa tarefa nem sempre é de fácil execução, pois essa região apresenta-se normalmente radiotransparente (mais escura) devido à predominância de tecido adiposo próximo ao contorno. O menor contraste existente nesta região, torna-se sensível à presença de ruído, prejudicando a definição de seu contorno numa detecção automática e digital.

A segmentação precisa da região da mama é essencial para as etapas de detecção e análise de lesões. É, também, fundamental para comparação bilateral, quando o alinhamento entre as mamas é necessário. A localização do mamilo depende também da determinação do contorno da mama, pois ele repousa sobre a sua superfície.

Apresentamos as técnicas aplicadas utilizadas nesta etapa e, no final do capítulo, a avaliação das técnicas aplicadas.

5.1 Método de Limiarização

A limiarização (thresholding method) é o mais tradicional método de segmentação de imagem (Gonzalez, 2000,2001). Consiste em separar as regiões de uma imagem de acordo com um determinado critério ou propriedade retirados da imagem. Ela pode ser baseada em operadores de limiarização ou no histograma de nível de cinza da imagem. Na primeira técnica, o valor limiar é definido através de características da vizinhança do pixel. A segunda técnica baseia-se no histograma em nível de cinza da imagem.

O histograma, em mamografia, caracteriza a distribuição de densidade dos tecidos mamários presentes na imagem. Para mamas com alta densidade, o histograma apresenta uma distribuição maior próximo à faixa de alto valor de intensidade. Para mamas com densidade média, esta distribuição se desloca para intensidades intermediárias do histograma. No caso de mamas com baixa densidade, a distribuição maior ocorre na faixa de intensidade mais baixa. As imagens de incidência médio-lateral oblíqua aumentam a banda de alta intensidade devido à presença do tecido de músculo peitoral. As figuras 5.1 e 5.2 mostram os histogramas típicos de acordo com a composição 1, 2, 3 e 4 do padrão BI-RADS de imagens mamográficas das incidências CC e MLO, respectivamente.

A determinação do limiar pode ser feita escolhendo a tonalidade (nível de cinza) entre bandas de interesse no histograma. Por exemplo, nas figuras 5.1 e 5.2, os histogramas apresentam picos e vales que separam bandas de tonalidades que correspondem a um tipo de tecido da imagem mamográfica.

Existem vários métodos para determinar esses limiares ótimos de acordo com a banda de interesse. Iremos apresentar, dentre uma lista extensa de métodos, somente aqueles que foram investigados nesse trabalho. São eles: Princípio de Máxima Entropia (PME), Método de Preservação de Momento (MPM), Método de Otsu (OTSU), Método iterativo de Ridler & Calvard (RIDLER), Método iterativo de Reddi (REDDI) e Método

da Matriz de Co-ocorrência (MMCO).

FIGURA 5.1: Histogramas típicos de imagens da incidência crânio-caudal direita (CCD) apresentando densidade dos tecidos mamários de acordo com o padrão BI-RADS™: (a) composição 1; (b) composição 2; (c) composição 3; (d) composição 4. Os valores do eixo das ordenadas dos histogramas correspondem à quantidade de pixels para cada nível de cinza (0-255).

FIGURA 5.2: Histogramas típicos das mesmas imagens da figura 5.1 de incidência médio-lateral oblíqua direita (MLOD), apresentando densidade dos tecidos mamários de acordo com o padrão BI-RADS. (a) composição 1; (b) composição 2; (c) composição 3; (d) composição 4. Os valores do eixo das ordenadas dos histogramas correspondem à quantidade de pixels para cada nível de cinza (0-255).

5.1.1 Princípio de Máxima Entropia

Kapur et. al. (1985) propuseram um algoritmo de limiarização baseado na entropia de Shannon. Dada duas distribuições separadas por um limiar t , a entropia de cada classe é definida por

$$H_b(t) = - \sum_{i=0}^t \frac{p_i}{P_t} \ln \frac{p_i}{P_t} \quad (5.1)$$

$$H_w(t) = - \sum_{i=t+1}^{N-1} \frac{p_i}{(1-P_t)} \ln \left(\frac{p_i}{1-P_t} \right) \quad (5.2)$$

onde, $P_t = \sum_{i=0}^t p_i$ e N : número de nível de cinza, então, o limiar ótimo t^* é definido como o nível de cinza que maximiza a soma $H_b(t) + H_w(t)$, ou seja,

$$t^* = \arg \max_{0 \leq t \leq L-1} \{H_b(t) + H_w(t)\} \quad (5.3)$$

5.1.2 Método de Otsu

Este método, proposto por Otsu (1978), é baseado na seleção do ponto mais baixo (vale) entre dois picos no histograma.

Suponha a probabilidade do nível de cinza n_i em uma imagem com L níveis de cinza estimado por

$$p_i = \frac{n_i}{N}, \quad N = \sum_{i=1}^L n_i \quad (5.4)$$

Se os pixels na imagem são classificados entre duas classes C_0 e C_1 através do limiar t , então as probabilidades da classe ocorrerem e a média dos níveis de cinza são dadas por

$$\omega_0 = \sum_{i=1}^t p_i = P(t), \quad \omega_1 = \sum_{i=t+1}^L p_i = (1 - P(t)), \quad (5.5)$$

$$\mu_0 = \sum_{i=1}^t \frac{i \cdot p_i}{\omega_0} = \frac{\mu(t)}{\omega_0}, \quad (5.6)$$

$$\mu_1 = \sum_{i=t+1}^L \frac{i \cdot p_i}{\omega_1} = \frac{\mu_T - \mu(t)}{1 - P(t)}, \quad (5.7)$$

onde,

$$\mu(t) = \sum_{i=1}^t i \cdot p_i \quad \text{e} \quad \mu_T = \sum_{i=1}^L i \cdot p_i, \quad (5.8)$$

são os momentos de primeira ordem acumulados até o nível t e a média total dos níveis, respectivamente.

A variância entre as classes é definida como

$$\begin{aligned} \sigma_B^2(t) &= \omega_0 (\mu_0 - \mu_T)^2 + \omega_1 (\mu_1 - \mu_T)^2 = \omega_0 \omega_1 (\mu_1 - \mu_0)^2 \\ \sigma_B^2 &= \frac{[\mu_T P(t) - \mu(t)]^2}{P(t)[1 - P(t)]} \end{aligned} \quad (5.9)$$

e o limiar ótimo t^* é dado por

$$\sigma_B^2(t^*) = \max_{1 \leq t \leq L} (\sigma_B^2(t)) \quad (5.10)$$

Todos os limiares possíveis são avaliados e aquele que maximizar a variância é escolhido como limiar ótimo (t^*)

5.1.3 Método de Preservação do Momento

Neste método, apresentado por Tsai (1985), os valores de limiares são computados de tal forma que os momentos de uma imagem original f e a imagem limiarizada (binarizada) g têm momentos próximos.

O $i^{\text{ésimo}}$ momento m_i , da imagem f deve ser computado do histograma por:

$$m_i = \frac{1}{n} \sum_{g=0}^{t-1} g^i h(g), \quad i=1,2,3,\dots \quad (5.11)$$

onde, n é o número de pixels na imagem. O valor de limiar t^* é obtido do histograma de nível de cinza da imagem, escolhendo t^* como p_0 -tile, onde p_0 é dado por:

$$p_0 = \frac{z - m_1}{(c_1^2 - 4c_0)^{1/2}} \quad (5.12)$$

e

$$c_0 = \frac{m_1 m_3 - m_2^2}{m_2 - m_1^2}, \quad c_1 = \frac{m_1 m_2 - m_3}{m_2 - m_1^2},$$

$$z = \frac{1}{2} \left\{ (c_1^2 - 4c_0)^{1/2} - c_1 \right\} \quad (5.13)$$

O método **p-tile** assume uma imagem binarizada cuja porcentagem da área do objeto a ser segmentado é conhecida. O limiar é definido como o mais alto valor de nível de cinza que cobre no mínimo a porcentagem de pixels dentro dos objetos na imagem limiarizada (Doyle, 1962; Sahoo et al., 1988). Por exemplo, suponha que um objeto ocupe uma área de 20% de uma imagem, então a imagem poderá ser limiarizada até um certo valor de nível de cinza de tal forma que no mínimo 20% dos pixels são ocupados pelo objeto.

5.1.4 Método de Ridler & Salvard

O algoritmo, proposto por Ridler & Calvard (1978), descreve uma técnica iterativa baseada em critérios estatísticos.

1. Um valor inicial de limiar é assumido para t_k . Normalmente, adota-se a intensidade média do histograma em nível de cinza.
2. Divide-se a imagem em dois grupos de intensidades: $R_1 = [0, 1, \dots, t_k]$ e $R_2 = [t_k + 1, \dots, L - 1]$, onde t_k é o valor de limiar que separa os dois grupos e L é o nível de cinza máximo da imagem.
3. Calculam-se os valores de intensidade média μ_1 e μ_2 das partições R_1 e R_2

$$\mu_1(t_k) = \frac{\sum_{i=0}^{t_k} i p(i)}{\sum_{i=0}^{t_k} p(i)}, \quad \mu_2(t_k) = \frac{\sum_{i=t_k+1}^{L-1} i p(i)}{\sum_{i=t_k+1}^{L-1} p(i)} \quad (5.14)$$

4. Seleciona-se um novo valor de limiar t_{k+1} pela média entre $\mu_1(t_k)$ e $\mu_2(t_k)$

$$t_{k+1} = \frac{\mu_1(t_k) + \mu_2(t_k)}{2} \quad (5.15)$$

5. Repetir a etapas (2-4) até o valor de limiar permaneça estável, ou seja, $t_{k+1}=t_k$.

5.1.5 Método de Reddi

O método de Reddi et al. (1984) é também um método iterativo estendido do método de Otsu (1979) para múltiplos valores de limiares.

1. Selecionam-se dois valores iniciais de limiares t_1 e t_2 .
Normalmente, adotam-se valores iniciais como

$$t_1 = \frac{L}{3} \quad e \quad t_2 = \frac{2L}{3},$$

onde L é o valor de máxima intensidade.

2. Computam-se os seguintes valores

$$\begin{aligned} e_1(t_1, t_2) &= \frac{m(0, t_1) + m(t_1, t_2)}{2} - t_1, \\ e_2(t_1, t_2) &= \frac{m(t_1, t_2) + m(t_2, L)}{2} - t_2 \end{aligned} \quad (5.16)$$

com

$$m(t_i, t_j) = \frac{1}{t_j - t_i + 1} \sum_{g=t_i}^{t_j} g \cdot h(g) \quad (5.17)$$

3. Atualizando os valores de t_1 e t_2 da seguinte forma

$$\begin{aligned} t_1 &\leftarrow t_1 + e_1, \\ t_2 &\leftarrow t_2 + e_2 \end{aligned} \quad (5.18)$$

4. Se e_1 e e_2 estão abaixo de uma tolerância adotada, para-se a iteração; caso contrário, repete-se as etapas (2-3).

O método de Reddi et al. (1982) fornece dois valores de limiares t_1 e t_2 no final da execução do algoritmo.

5.1.6 Método da Matriz de Co-ocorrência

A matriz de co-ocorrência foi desenvolvida por Haralick et al. (1973) para análise de textura. Em geral, essa matriz $M_{(d,\theta)}$ é formada pela frequência relativa de ocorrência de dois pixels vizinhos com níveis de cinza i e j , separados pela distância d e com orientação θ . A figura 5.3 ilustra a definição das direções utilizadas por Haralick et al. (1973) para montar a matriz de co-ocorrência.

FIGURA 5.3: Definição dos ângulos usados na matriz de co-ocorrência.

0	0	1	1
0	0	1	1
0	2	2	2
2	2	3	3

(a)

$$\begin{array}{cccc}
 \begin{bmatrix} 2 & 1 & 3 & 0 \\ 1 & 2 & 1 & 0 \\ 3 & 1 & 0 & 2 \\ 0 & 0 & 2 & 0 \end{bmatrix} &
 \begin{bmatrix} 6 & 0 & 2 & 0 \\ 0 & 4 & 2 & 0 \\ 2 & 2 & 2 & 2 \\ 0 & 0 & 2 & 0 \end{bmatrix} &
 \begin{bmatrix} 4 & 1 & 0 & 0 \\ 1 & 2 & 2 & 0 \\ 0 & 2 & 4 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix} &
 \begin{bmatrix} 4 & 2 & 1 & 0 \\ 2 & 4 & 0 & 0 \\ 1 & 0 & 4 & 1 \\ 0 & 0 & 1 & 2 \end{bmatrix} \\
 \text{(b)} & \text{(c)} & \text{(d)} & \text{(e)}
 \end{array}$$

FIGURA 5.4: (a) exemplo de Matrizes de Co-ocorrência com $d=1$ de uma imagem 4×4 com 4 níveis de cinza (0-3). (b) $\theta = 135^\circ$; (c) $\theta = 90^\circ$; (d) $\theta = 45^\circ$; (e) $\theta = 0^\circ$;

A figura 5.4 mostra um exemplo da montagem da Matriz de Co-ocorrência a partir de uma imagem. Note que nas linhas diagonais das matrizes são registradas as frequências de ocorrência de vizinhos com o mesmo nível de cinza. Fora da diagonal são registradas, as frequências de ocorrência de vizinhos com níveis de cinza diferentes. Portanto, em faixas onde há homogeneidade de tonalidade, pixels com a mesma intensidade irão contribuir, principalmente, na linha diagonal da Matriz de Co-ocorrência. Pixels próximos à borda do objeto, contribuirão, principalmente, fora da entrada diagonal da Matriz de Co-ocorrência. Baseado nisso, podemos definir dois histogramas a partir da matriz de co-ocorrência:

(a) Um histograma baseado nas entradas da diagonal da Matriz de Co-ocorrência. Este histograma poderá ter vales entre os níveis de cinza do objeto e fundo da imagem.

(b) Um histograma baseado nas entradas fora da diagonal da Matriz de Co-ocorrência. Este histograma poderá ter picos entre os níveis de cinza do objeto e fundo da imagem.

Um limiar para a imagem pode, então, ser escolhido de uma faixa de níveis de cinza em que os vales no histograma (a) coincidem com os picos do histograma (b).

5.2 Preparação das imagens para o processo de segmentação

Após o pré-processamento descrito no capítulo 4, foram aplicados os algoritmos de segmentação: Princípio de Máxima Entropia (PME), Método de Preservação de Momento (MPM), Método de Otsu (OTSU), Método de Ridler & Calvard (RIDLER), Método de Reddi (REDDI) e o Método Matriz de Co-ocorrência (MMCO).

A resolução de nível de cinza foi alterada de 12 bits (4096 níveis de cinza) para 8 bits (256 níveis de cinza) para diminuir o custo computacional, pois a utilização de histograma e da Matriz de Co-ocorrência de nível de cinza em imagens com alta resolução de quantização, aumenta o custo computacional dos algoritmos de segmentação.

5.3 Obtenção do valor de limiar ótimo e avaliação do processo de segmentação

As imagens selecionadas foram submetidas aos algoritmos de segmentação e o valor de limiar foi obtido para cada um dos métodos aplicados.

As imagens segmentadas foram, então, submetidas à avaliação supervisionada para a escolha do *limiar ótimo* da melhor imagem segmentada, ou seja, avaliou-se qual método teve melhor desempenho de segmentação para aquela imagem. As figuras 5.5 e 5.6 ilustram a seqüência de imagens segmentadas. O valor de limiar é apresentado no topo de cada imagem limiarizada sem a identificação do método utilizado, e a seqüência dos métodos foi apresentada de modo aleatório.

Para muitas imagens, o valor de *limiar ótimo* coincidiu para métodos diferentes devido às características da imagem serem apropriadas para essas técnicas.

Das informações obtidas desse processo, foi computado o número de vezes que o valor *limiar ótimo* foi escolhido para cada método. Esses valores foram compilados separadamente para cada tipo de incidência (CCD, CCE, MLOD e MLOE) e com todas as incidências juntas. Com isso, foi possível analisar o melhor método para o processo de segmentação.

5.4 Remoção de artefatos e suavização inicial da borda da imagem segmentada

Após a segmentação das imagens, artefatos e a identificação da incidência da mama permaneceram no fundo da imagem e objetos espúrios apareceram conectados à borda da mama. Em algumas imagens, principalmente da mama do lado esquerdo, os ruídos permaneceram na região pósterio-externa da mama. Essa presença de ruído se deve a dois fatores: alta densidade de ruído nesta região e a proximidade de valores de intensidade entre os pixels representando o ruído e os tecidos da mama presentes nesta região. Os algoritmos se mostraram sensíveis a esses fatores. A figura 5.7 mostra dois exemplos de imagens antes e após a limiarização.

Para suavizar o contorno da mama, quebrar istmos estreitos, e eliminar objetos espúrios na imagem, aplicamos filtros morfológicos de fechamento e abertura (Serra, 1998).

A abertura corresponde à operação de um conjunto **A** por um elemento estruturante **B**, denotada por $A \circ B$, definida como

$$A \circ B = (A \ominus B) \oplus B \quad (5.19)$$

onde, $\ominus$ é o operador morfológico de erosão e $\oplus$ é o de dilatação. Ou seja, a operação de abertura de **A** por **B** é simplesmente a erosão de **A** por **B** seguido da dilatação do resultado por **B**.

A operação de fechamento de **A** por um elemento estruturante **B**, denotada por $A \bullet B$, é definida como

$$A \bullet B = (A \oplus B) \ominus B \quad (5.20)$$

significando que o fechamento de **A** por **B** é simplesmente a dilatação de **A**

por **B** seguida da erosão do resultado por **B**.

Nas imagens de nosso trabalho aplicamos os filtros morfológicos de fechamento e abertura com elemento estruturante circular com raios iguais a 3, 5 e 11 pixels. Para artefatos e objetos remanescentes no fundo da imagem, foram desenvolvidas rotinas específicas e utilizadas funções da biblioteca de ferramentas (toolbox) de morfologia do MATLAB®.

5.5 Suavização final com a aplicação da interpolação cúbica B-spline

A interpolação Spline é especificada por um conjunto de posições denominados de *pontos de controle* (Th'evenaz et al., 2000). A função base é dada por:

$$x(u) = \sum_{k=0}^3 g_k \cdot B_k(u) \quad (5.21)$$

Existem vários tipos de spline. Os mais conhecidos são B-spline, curvas de Bézier, Hermite Interpolation, Natural Cubic Spline, Cardinal Splines e Kochanek-Bartels Splines.

O interesse neste trabalho recaiu sobre o B-spline devido às vantagens de ajuste do grau do polinômio independente do número de pontos de controle e permissão de ajuste local sobre a forma da curva.

A expressão geral da B-spline é dada por:

$$P(u) = \sum_{k=0}^n p_k B_{k,d}(u), \quad u_{min} \leq u \leq u_{max}, \quad 2 \leq d \leq n+1 \quad (5.22)$$

onde, p_k é um conjunto de $(n+1)$ pontos de controle e as funções de mistura B-spline $B_{k,d}$ são polinômios de grau $(d-1)$.

Funções de mistura são definidas pelas fórmulas de recursão:

$$B_{k,1} = \begin{cases} 1, & \text{se } u_k \leq u \leq u_{k+1} \\ 0, & \text{senão} \end{cases} \quad (5.23)$$

$$B_{k,d} = \frac{u - u_k}{u_{k+d-1} - u_k} B_{k,d-1}(u) + \frac{u_{k+d} - u}{u_{k+d} - u_{k+1}} B_{k+1,d}(u) \quad (5.24)$$

onde, cada função de mistura é definida sobre d subintervalos do domínio em u . O conjunto de valores u_j é chamado de vetor de nós (*knot vector*).

Curvas, cujo valor do espaçamento entre os nós é constante, determinam uma B-spline periódica e uniforme e possuem funções de mistura periódicas e cada uma é uma versão deslocada da anterior.

$$B_{k,d}(u) = B_{k+1,d}(u + \Delta u) = B_{k+2,d}(u + 2\Delta u) \quad (5.25)$$

onde Δu é o intervalo entre nós adjacentes.

A interpolação B-spline, utilizada freqüentemente em pacotes gráficos, é a B-spline cúbica e periódica. São úteis no desenho de curvas fechadas. Para essas curvas, $d=4$ e as funções de mistura, divide-se em quatro intervalos do alcance total de u .

Para B-spline não uniformes, valores e intervalos para o vetor de nós são escolhidos livremente, oferecendo maior flexibilidade no controle da forma de curvas.

Para a suavização da borda da mama, utilizamos B-spline cúbica e uniforme com pontos de controle em intervalos constantes de 32 pixels. Esse valor foi obtido empiricamente e teve o objetivo de suavizar a borda da mama e preservar principalmente o contorno do mamilo quando se apresentava na imagem.

A figura 5.7 (c) e (f) apresenta as imagens suavizadas com interpolação B₃-spline. Verifique que a borda da mama foi suavizada de modo satisfatório, inclusive a base da mama que apresentava ruídos após a limiarização.

5.6 A imagem segmentada e a avaliação do processo de restauração

Todo o processo executado nesta etapa de processamento da imagem, teve o objetivo de obter uma imagem sem ruído, artefatos e objetos que não pertencesse à estrutura anatômica da mama.

FIGURA 5.5: (a) apresenta uma imagem da base de imagens e a limiarização realizadas pelos métodos: (b) PME, (c) MPM, (d) OTSU, (e) RIDLER, (f) MMCO, (g) e (h) REDDI.

FIGURA 5.6: (a) apresenta uma imagem da base de imagens e a limiarização realizadas pelos métodos: (b) PME, (c) MPM, (d) OTSU, (e) RIDLER, (f) MMCO, (g) e (h) REDDI.

Para concluir a produção da imagem final, aplicamos a operação de multiplicação da imagem segmentada com a imagem original e aplicamos novamente o filtro de Wiener. A figura 5.8 apresenta uma imagem original e os processos de restauração.

A avaliação da restauração foi realizada visualmente por um radiologista experiente, como medida de qualidade do método. Uma nota foi dada de acordo com a estimativa obtida pelo método. Para a restauração exata foi dada *nota 3*, para uma restauração aceitável, foi atribuída *nota 2* e para restauração inaceitável, a *nota 1*.

FIGURA 5.7: Ilustra as imagens após a limiarização e as operações de retirada de artefatos e objetos espúrios que permaneceram na imagem. Em (a) e (d), a imagem antes da limiarização; em (b) e (e), a imagem após a limiarização; em (c) e (f), a imagem após a aplicação do filtro morfológico de fechamento e abertura, rotinas para retirada de artefatos e objetos de fundo da imagem e a aplicação de interpolação B_3 -spline para suavização final da borda da mama.

FIGURA 5.8: O resultado do processo de restauração da imagem. Em (a) e (d), a imagem original; em (b) e (e), após a pré-filtragem com Wiener e Equação de Difusão Anisotrópica; e em (c) e (f), após os processos de segmentação, retirada de ruído e artefatos, e suavização.

Capítulo 6

Detecção automática da região do músculo peitoral, localização da posição do mamilo e segmentação da região dos tecidos fibro-glandulares

Neste capítulo, são descritas as técnicas utilizadas na detecção da região do músculo peitoral, na localização da posição do mamilo e a região com tecidos fibro-glandulares.

6.1 A transformada de Radon

A transformada de Radon (TR) é baseada na transformada de Fourier. Ela computa a soma projetada de intensidades ao longo de uma direção da imagem. Essa soma de intensidades se transforma em um ponto no domínio Radon, $R(t, \theta)$, onde t é a distância perpendicular em relação ao centro da imagem (considerada a origem no domínio da imagem), e θ é o ângulo entre a distância perpendicular e o eixo x da coordenada da imagem (figura 6.1). Desta forma, a transformada de Radon torna-se uma ferramenta útil para localização de estruturas lineares na imagem. A função da transformada é definida como:

$$R(t, \theta) = \int_{-\infty}^{+\infty} A(t \cdot \cos \theta - u \cdot \sin \theta, t \cdot \sin \theta + u \cdot \cos \theta) du \quad (6.1)$$

FIGURA 6.1: ilustra a função $A(x,y)$ na transformada de Radon $R(t, \theta)$.

Deans (1981) mostra que há uma estreita relação entre a transformada de Hough e Radon. De fato, a transformada de Hough (TH) é um caso especial da transformada de Radon. TR tem sua origem de transformada no centro da imagem original enquanto TH tem sua origem na localização da imagem onde os índices de linha e coluna são zero (origem da imagem). A TH é computacionalmente eficiente somente em imagens binárias enquanto a TR em imagens binárias e em níveis de cinza (Deans, 1981). A figura 6.2 ilustra a comparação entre as duas transformadas. Para a distância ρ é calculada em relação à origem $(0,0)$ da imagem original, enquanto para a TR essa distância ρ é calculada em relação ao centro da imagem (Rangayyan & Rolston, 1998).

FIGURA 6.2: Comparação entre os mapeamentos da transformada de Hough e de Radon (Rangayyan, 1998).

As imagens no domínio espacial podem ser apresentadas no domínio das TR e TH. A figura 6.3 apresenta um exemplo de uma imagem em nível de cinza e sua transformada de Radon. O valor de $R(t, \theta)$ foi normalizado entre (0-1). O eixo vertical corresponde à distância t e o eixo horizontal corresponde à direção θ . No domínio de Radon, as intensidades mais altas correspondem às direções e distâncias que apresentam maior densidade de tecidos mamários ao longo desta direção.

Em imagens binarizadas e com bordas detectadas, as intensidades mais altas no domínio de Radon, correspondem às linhas retas ao longo destas direções (Liu et al., 1991; Rangayyan & Rolston, 1998). A figura 6.4 apresenta uma imagem binarizada submetida ao operador Sobel de detecção de borda e a detecção das linhas retas pela transformada de Radon. Os pontos com maior intensidade no domínio de Radon correspondem às linhas retas na imagem.

6.2 Detecção da linha da região do músculo peitoral pela transformada de Radon

Na incidência médio-lateral oblíqua da mamografia, a região do músculo peitoral pode ser separada da região com tecidos mamários por uma linha reta com inclinação angular entre 90° e 135° , para a mama direita e 45° e 90° , para a mama esquerda.

Para detectar esta linha reta, aplicamos um operador de detecção de borda da região do músculo peitoral e a transformada de Radon para detecção dessa linha. Existem várias funções amplamente utilizadas para

detecção de borda (Sobel, Roberts, Spline, Marr & Hildreth (Laplaciano do Gaussiano), Canny, etc). Escolhemos o operador de Canny devido à sua capacidade de detecção da borda estimando a direção do gradiente de suavização (Canny, 1986).

O detector de borda de Canny é baseado no filtro Gaussiano de suavização com desvio padrão σ . Ele, diferentemente do operador de Marr-Hildreth que usa o filtro laplaciano após a suavização gaussiana, usa um operador direcional. Primeiro, a imagem é suavizada com a operação de convolução da imagem com o filtro 2D-Gaussiano e simétrico. Para determinar a direção do gradiente, perpendicular ao sentido da borda, é aplicada a segunda derivada do filtro Gaussiano e é identificado o máximo local.

$$\frac{\partial^2}{\partial n^2} G * f = 0 \quad , \quad (6.2)$$

onde G é o filtro 2D-Gaussiano, f é a imagem e n é a direção do operador.

A limiarização é feita usando o método de 'histerese'. Considerando um segmento de borda, os pixels com valores acima do limite superior de limiarização são aceitos, e os de valores abaixo do limite inferior de limiarização são rejeitados. Pixels com valores intermediários devem ser aceitos se estiverem relacionados com pixels de borda considerados fortes.

Um fator importante do operador de Canny é a escolha do valor de desvio-padrão (σ). Quanto maior o valor de σ , maior é a capacidade de suavização de detalhes e menor influência do ruído. Por outro lado, menor valor de σ , produz detalhes finos mas aumenta a sensibilidade ao ruído (Loh et al., 2001). Aplicamos o operador de Canny e variamos o valor de σ entre 1 e 10 para as imagens bilaterais de incidência médio-lateral oblíqua.

Várias retas candidatas foram detectadas pela transformada de Radon no intervalo de $\{5^0, 50^0\}$ para a mama direita, e de $\{-5^0, -50^0\}$ para a mama esquerda. Os critérios de máxima intensidade no domínio de Radon foram adotados para a escolha das retas candidatas. A linha reta final para um determinado valor de desvio-padrão σ foi selecionada pelo critério de máxima intensidade e da posição da reta próxima da parede torácica. A

figura 6.5 apresenta uma imagem com as retas candidatas e a reta final escolhida com $\sigma = 8$ para o operador de Canny.

6.3 Avaliação da detecção da região do músculo peitoral

As avaliações do processo de detecção da região de músculo peitoral encontrados na literatura variam entre inspeções visuais simples realizados por especialistas (Kassemeijer, 1998), ou por avaliações comparativas com o traçado manual realizados por especialistas (Ferrari et al., 2004; Zhou et al., 2001). Em alguns trabalhos, a avaliação é omitida por não participar do enfoque principal do trabalho (Ojala et al., 2001; Sallam & Bowyer, 1999; Yam et al., 2001). Em nosso trabalho, utilizamos um método quantitativo baseado na comparação com o traçado realizado por um especialista.

O primeiro procedimento foi determinar o valor “ótimo” para o valor de σ que melhor resultado ofereceu na detecção da borda da região do músculo peitoral. Para cada imagem de mamografia foram obtidas 10 linhas de acordo com cada valor de σ aplicado no operador de Canny. Para determinar o valor “ótimo” de σ escolhido para ser adotado para todas as imagens, foi calculado o erro da raiz da média quadrática (E_{RMS}) entre a linha detectada automaticamente e a definida por um radiologista especialista. Considerando duas retas, r e s , que cortam a imagem, o erro médio quadrático foi calculado por

$$E_{RMS} = \frac{1}{K} \sqrt{\sum_{i=1}^K \left[(x_i^r - x_i^s)^2 + (y_i^r - y_i^s)^2 \right]} \quad (6.2)$$

onde,

(x_i^r, y_i^r) são pontos da reta r , obtidos por $y_i^r = \alpha_r x_i^r + \beta_r$,

(x_i^s, y_i^s) são pontos da reta s , obtidos por $y_i^s = \alpha_s x_i^s + \beta_s$ e

$i = 1, 2, 3, \dots, k$, sendo que K foi determinado pelo número máximo de pontos entre as duas retas, r e s , que estavam contidos nos limites da região da mama na imagem (figura 6.6).

FIGURA 6.3: ilustração de uma imagem em nível de cinza (a) e sua transformada de Radon (b).

FIGURA 6.4: ilustração de uma imagem binarizada com a detecção de borda realizada com o operador de Sobel (a) e sua transformada de Radon (b).

FIGURA 6.5: Ilustra a detecção da linha que separa a região do músculo peitoral. Na imagem em nível de cinza (a) é aplicado o operador de detecção de borda de Canny com $\sigma=8$ (b) e a transformada de Radon para detecção das retas candidatas (c) e por um critério de intensidade no domínio de Radon e posição da reta, é seleciona da reta (d). As imagens foram equalizadas para visualização.

FIGURA 6.6: Desenho ilustrativo de duas retas, r e s , para o cálculo do erro médio quadrático. São utilizados todos os pontos dentro dos limites da imagem da reta s e da reta r (linha cheia) e, neste exemplo, os pontos estendidos da reta r (linha pontilhada).

Os valores obtidos pela equação foram fornecidos em pixels. Como utilizamos mamografias com tamanhos diferentes, essa medida levaria a dificuldade na avaliação. Para fornecer um valor mais preciso do erro, estabelecemos o erro em milímetro, calculado pelo erro em pixels multiplicado pelo seu tamanho na imagem (seção 3.2) e calculamos o erro médio quadrático.

6.4 Localização do mamilo pela transformada de Radon

Para detectar a região do mamilo, consideramos características importantes da anatomia da mama: o mamilo pertence à estrutura anatômica de superfície da mama. Os tecidos glandulares possuem estruturas (lóbulos, alvéolos e ductos) que convergem em direção ao mamilo. Esses tecidos possuem densidade radiológica mais elevada do que o tecido adiposo, localizado principalmente próximo ao contorno da mama e na região posterior, próxima ao espaço retro-mamário.

Para determinar a localização do mamilo, a idéia inicial é localizar na mama, próximo ao mamilo, um ponto em que as direções dos tecidos se concentram. Conhecido esse ponto, determinar em que direção ocorre a maior concentração de densidade na região da mama e que passe pelo ponto de convergência.

Aplicamos primeiramente na imagem original em nível de cinza o filtro morfológico TopHat. O filtro utiliza a operação de fechamento de acordo com um elemento estruturante e a seguir subtrai a imagem filtrada da imagem original. Com isso, realça os objetos que casam com a forma do elemento estruturante e diminui o brilho de elementos de fundo (figura 6.7b e 6.8b).

Aplicamos a transformada de Radon nas imagens após o filtro TopHat para uma faixa de ângulos de direção de: $45^{\circ} \leq \theta \leq 135^{\circ}$ para a mama direita e incidência CC, $-45^{\circ} \leq \theta \leq -135^{\circ}$ para a mama esquerda e incidência CC, $45^{\circ} + \alpha \leq \theta \leq 135^{\circ} + \alpha$ para a mama direita e incidência MLO e $-45^{\circ} - \alpha \leq \theta \leq -135^{\circ} - \alpha$ para a mama esquerda e incidência MLO, onde α é a

direção da linha de separação da região do músculo peitoral, e θ é a direção da projeção na TR. Obtivemos, com isso, os valores de $R(t, \theta)$ no domínio de Radon. Os valores máximos de $R(t, \theta)$ correspondem às direções na imagem em que ocorre a maior concentração de densidade na região da mama. Para as incidências MLO, a região de músculo peitoral foi retirada. Essas projeções foram representadas por linhas retas que convergiram para um ponto próximo do mamilo. O ponto que possuía o maior número de retas coincidentes, foi selecionado como o ponto de convergência (pc). A posição do mamilo, devido às características anatômicas adotadas, deve pertencer à borda da mama. Portanto, para determinar a posição do mamilo, foi preciso achar uma linha reta que passasse pelo ponto de convergência (pc) e cortasse a borda da mama. Para selecionar essa linha reta, aplicamos a TR na imagem em nível de cinza sem aplicação do filtro TopHat e localizamos, no domínio de Radon, o valor máximo de $R(s, \theta)$ que passa pelo ponto de convergência. Essa direção representou a linha reta para determinação da posição do mamilo. As figuras 6.7 e 6.8 ilustram a aplicação do método para a localização da posição do mamilo das vistas CC e MLO, respectivamente.

6.5 Avaliação da localização do mamilo

Para avaliar o algoritmo, um radiologista especialista determinou a posição do mamilo por método visual. A detecção automática foi avaliada calculando o erro médio quadrático (E_{RMS}) em relação à posição detectada manualmente. Os valores obtidos pela equação foram fornecidos em pixels e da mesma forma que a avaliação realizada para detectar o músculo peitoral, estabelecemos o erro em milímetros. A equação de E_{RMS} é dada por:

$$E_{RMS} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (6.3)$$

onde, (x_i, y_i) e (x_j, y_j) são as posições do mamilo detectado de modo manual e automaticamente.

FIGURA 6.7: ilustra a aplicação da transformada de Radon para detecção da posição do mamilo. (a) imagem da incidência CC; (b) a imagem após a aplicação do filtro TopHat; (c) imagem com as linhas selecionadas para determina o ponto de convergência (pc); (d) mostra a posição do ponto de convergência e do mamilo.

FIGURA 6.8 – ilustra a aplicação da transformada de Radon para detecção da posição do mamilo. (a) imagem da incidência MLO; (b) a imagem após a aplicação do filtro TopHat; (c) imagem com as linhas selecionadas para determina o ponto de convergência (pc); (d) mostra a posição do ponto de convergência e do mamilo.

6.6 Segmentação da região dos tecidos fibro-glandulares

A segmentação da região densa foi feita da mesma forma que na segmentação da região da mama. Foram escolhidos empiricamente, nesta etapa, somente os métodos de Princípio de Máxima Entropia (PME), o método de Otsu (OTSU) e o Método de Preservação de Momento (MPM). A descrição desses métodos se encontra na seção 5.2.

As imagens foram submetidas aos algoritmos de segmentação e o valor de limiar foi obtido para cada um dos métodos aplicados. A seguir, as imagens foram submetidas à avaliação supervisionada para a escolha do *limiar ótimo* para cada imagem. As figuras 6.9 e 6.10 ilustram a sequência de imagens segmentadas. Das informações obtidas desse processo, foi computado o número de vezes que o valor *limiar ótimo* foi escolhido para cada método. Esses valores foram compilados separadamente para tipo de incidência (CCD, CCE, MLOD e MLOE) e com todas as incidências juntas. Com isso, pode-se avaliar o melhor método para o processo de segmentação da região densa.

FIGURA 6.9: Sequência de imagens para limiarização da região composta por tecido fibro-glandular. A imagem original (a) da vista CC foi submetida aos métodos de (b) Princípio de Máxima Entropia, (c) Método de Preservação de Momento e (d) Método de Otsu.

FIGURA 6.10: Seqüência de imagens para limiarização da região composta por tecido fibro-glandular. A imagem original (a) da vista MLO foi submetida aos métodos de (b) Princípio de Máxima Entropia, (c) Método de Preservação de Momento e (d) Método de Otsu.

Capítulo 7

Extração de atributos visuais em mamogramas.

Os atributos são imprescindíveis para caracterizar e discriminar um objeto em uma imagem. São propriedades mensuráveis dos objetos como a cor, forma, textura, topologia, representação espectral e de fronteira que representam as características da imagem (Gonzalez & Woods, 2000, 2001). Esses atributos correspondem às características primitivas ou lógicas de uma imagem (Gudivada & Raghavan, 1995). Porém, ao analisar uma imagem, informações abstratas também são extraídas baseadas em conhecimento e conceitos relacionados, principalmente, a percepção humana que em sistemas automáticos, são muitas vezes desprezados. Os atributos utilizados levando em consideração esse aspecto, são chamados de atributos visuais.

O objetivo deste capítulo é apresentar um conjunto de atributos para análise visual com características próprias que discriminem conteúdos existentes nas imagens de mamografia e que permitam a relação com outras imagens mamográficas através de similaridade de conteúdo.

Os atributos utilizados pertencem aos grupos de textura e forma. Para extrair os atributos, cuidados foram reservados à adoção da região de interesse. Os atributos de forma utilizaram a imagem com região da mama binarizada. Os outros atributos utilizaram a imagem da região de tecido fibro-glandular segmentada em nível de cinza. Adotamos, também, a divisão da mama em regiões que formam o critério de quadrantes e aplicamos os

algoritmos de extração a cada uma destas regiões, formando pares de atributos da imagem. As imagens de incidência MLO foram processadas após a detecção e remoção da região do músculo peitoral.

7.1 Modelo de divisão da mama em quadrantes

Como apresentado na seção 1.2, um dos padrões utilizados pelos radiologistas para descrição de achados na mamografia é o sistema de quadrantes: QSE, QSI, QIE e QII.

Para realizar a análise por quadrantes, o médico radiologista tem à disposição mamografias das incidências básicas crânio-caudal (CC) e médio-lateral oblíqua (MLO). Devido a bi-dimensionalidade das imagens, a divisão por quadrantes é analisada subdividindo a mamografia em regiões nas duas incidências básicas. A incidência CC fornece a sub-região externa e interna, enquanto a incidência MLO fornece a sub-região superior e inferior da mama. A figura 7.1 fornece a divisão das duas mamas em regiões nas incidências CC e MLO. Observe que essa divisão utiliza, na projeção CC, a referência da posição do mamilo e a linha da parede torácica; para a projeção MLO, a posição do mamilo e a linha da região do músculo peitoral são utilizadas como referência.

Baseando-se neste fato, dividimos as duas incidências em regiões de interesse. Na projeção CC, obteve-se a região externa e a região interna; na projeção MLO, a região superior e região inferior. As regiões de interesse foram obtidas da imagem com a região fibro-glandular segmentada.

A adoção da posição do mamilo e da linha que separa a região do músculo peitoral como referência para a divisão, evidenciou a necessidade dos processos anteriores de detecção desses parâmetros em nosso trabalho de pesquisa.

Para cada região de interesse, extraímos os atributos de textura de Haralick, os atributos de momento de Hu, os atributos de Momentos estatísticos extraídos do histograma, e atributos espectrais extraídos do domínio de Radon. Atributos de medida de Granulometria foram extraídos direto da imagem sem a segmentação da região fibro-glandular e sem a

divisão em regiões de interesse. Atributos de Forma foram extraídos da imagem binarizada e também sem a divisão por regiões de interesse. Esses atributos fazem parte da classe de descritores regionais descritos por Gonzalez & Woods (2000,2001). A tabela 7.1 relaciona o número de atributos extraídos e a origem da extração destes atributos.

TABELA 7.1: Relação do grupo de atributos de forma e textura, a origem da extração e o número de atributos extraídos

Atributos	Origem da extração	# por região	# total
Forma	Região da mama binarizada	3	3
Textura de Haralick	Matriz de co-ocorrência das regiões de interesse	14	28
Momentos de Hu	Regiões de interesse	7	14
Momentos estatísticos	Histograma das regiões de interesse	6	12
Domínio de Radon	Domínio de Radon das regiões de interesse	10	20
Medida de Granulométrica	Região fibro-glandular da mama em nível de cinza	13	13

7.2 Atributos de forma

Objetos de uma classe podem ser distinguidos de outros objetos pela sua forma. Existem descritores básicos como área e perímetro de um objeto que podem discriminá-lo quanto à relevância de sua dimensão. Outros atributos podem fornecer medidas de discriminação das dimensões do objeto realizando relações entre medidas básicas do objeto. Essa relação, muitas vezes, torna o atributo invariante às dimensões do objeto. Da mesma forma que o tamanho da mama, a forma geométrica, por exemplo, alongada ou circular, podem ser relevantes na análise do objeto.

Investigamos os seguintes atributos de forma: área, solidez e razão

de diâmetro. Esses atributos são de fácil implementação e de baixo custo computacional.

7.2.1 Medida de área

A mais simples maneira de calcular a área de um objeto em uma imagem, é contar o número de pixels do objeto. Se a imagem está binarizada e o objeto é branco em fundo preto, basta contar o número de pixels correspondendo ao objeto. Em imagem em nível de cinza, a área do objeto de interesse poderá ser calculada pela contagem da frequência de pixels dos níveis de cinza que pertence ao objeto. Pode-se, neste caso, utilizar o histograma da imagem. De qualquer forma, o número de pixels (N) pode ser determinado por

$$N = \sum_g^L h(g) \quad (7.1)$$

sendo L o número de níveis de cinza do objeto, $h(g)$ a frequência de nível de cinza g que pertence ao objeto.

Para as imagens de nosso trabalho, normalizamos o valor de N e transformamos o valor da área em milímetros. Para isso, usamos a seguinte equação:

$$A = \frac{N \times tp}{n^2} \quad (7.2)$$

onde, A é a área da região da mama, n^2 é o número total de pixels na imagem e tp o tamanho do pixel. No caso de imagens mamográficas, o tamanho do pixel variou entre 0,2235 mm e 0,2794 mm.

FIGURA 7.1: Desenho ilustrativo da divisão da mama em sub-regiões.

7.2.2 Medida de razão de diâmetro

Para calcular a medida de razão de diâmetro, determinamos a distância compreendida entre a parede torácica e o mamilo, obtendo-se o diâmetro D_y . Em seguida, determinamos o diâmetro D_x definido pela distância entre os dois extremos da mama, cuja direção é perpendicular à direção de D_y e passa pelo ponto médio desse diâmetro. Para a mama da projeção MLO, a direção da linha que separa a região do músculo peitoral foi usada como referência para determinação de D_y e D_x .

Esse atributo fornece o grau de alongação da forma da mama. Quanto maior o valor do atributo, mais alongado será a sua forma; caso contrário, a mama terá a forma achatada. Se $D_y \approx D_x$, a forma da mama se aproxima de uma circunferência. A figura 7.2 ilustra a localização dos diâmetros para o cálculo da razão que é dada por

$$R_D = \frac{Dy}{Dx} \quad (7.3)$$

7.2.3 Medida de Solidez

Esta medida, também conhecida como grau de compactação ou compacidade, determina a razão do perímetro (P) e a área do objeto (A) (Pohlman et al., 1996).

$$S = \frac{P}{A} \quad (7.4)$$

Uma forma de contornar problemas computacionais, foi restringir os valores entre $[0,1]$ (Rangayyan et al., 1996). Desta forma, alteramos equação para:

$$S = 1 - \frac{2\pi A}{P^2} \quad (7.5)$$

Observe que para objetos com forma semicircular, o valor da solidez será de zero e aumenta de acordo com a complexidade ou rugosidade da forma.

A figura 7.3 mostra duas imagens com formas diferentes. Os valores dos atributos de forma dessas imagens são apresentados na tabela 7.2.

FIGURA 7.2: Desenho ilustrativo da posição dos diâmetros extraídos para o cálculo da medida de razão de diâmetros.

FIGURA 7.3: Imagens binarizadas com formas diferentes.

TABELA 7.2: Medidas de atributos de forma extraídos das imagens da figura 7.3 (área, solidez e razão de diâmetro).

Imagem	Área (A)	Solidez (S)	Razão de Diâmetro (R_D)
Imagem (a)	0,0998	0,7958	1,5916
Imagem (b)	0,0211	0,8087	0,7904

7.3 Atributos de textura de Haralick

Textura é uma importante característica usada para identificar objetos ou regiões de interesse numa imagem. A textura contém informações sobre a distribuição espacial de variações de tonalidades dentro de uma banda. Esse descritor fornece medidas de propriedades como suavidade, rugosidade e regularidade de uma região da imagem. Essas propriedades são detectadas utilizando-se matrizes de co-ocorrência de níveis de cinza que calculam a probabilidade combinada entre direção e distância entre pares de pixels (seção 5.1.6).

Haralick et al. (1973) sugerem 14 atributos de textura que podem ser extraídos das matrizes de co-ocorrência: Variança, Correlação, Contraste,

Entropia, Soma da Entropia, Diferença da Entropia, Momento da Diferença Inversa (MDI), Média da Soma, Variança da Soma, Média da Diferença, Variança da Diferença, Energia, Medida de Informação de Correlação 1 (MIC₁), e Medida de Informação de Correlação 2 (MIC₂).

A *variança* indica a variação da tonalidade da imagem. A *correlação* indica a homogeneidade de tonalidade da imagem. O *contraste* indica a variação de tonalidade entre regiões da imagem. A *entropia* indica a desorganização de tonalidade na imagem. A *soma e diferença de entropia* indicam a quantidade de desorganização entre tonalidades da imagem. O *momento da diferença inversa* indica a média de tonalidades entre pares de pixels. A *média da soma* indica a média de tonalidades entre pares de pixels. A *variança da soma* indica a variação de tonalidades entre pares de pixels. A *média da diferença* indica a homogeneidade da distribuição da tonalidade. A *variança da Diferença* é similar a variança da soma, mas com média centrada em zero. A *energia* indica a uniformidade ou suavidade de tonalidade na imagem. A *medida de correlação 1* indica a correlação da entropia para elementos independentes e pares de elementos da imagem. A *medida de correlação 2* indica a média da correlação baseada na similaridade entre entropias de elementos independentes e pares de elementos da imagem.

A seguir, são apresentadas as fórmulas dos descritores de Haralick.

$$\text{Variança} = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} (i - \mu_x)(j - \mu_y)p(i, j) \quad (7.6)$$

onde n é o número de níveis de cinza da imagem e $p(i, j)$ é o elemento i, j da matriz de co-ocorrência de nível de cinza (SGLD).

$$\text{Correlação} = \frac{\sum_{i=0}^{n-1} \sum_{j=0}^{n-1} (i - \mu_x)(j - \mu_y)p(i, j)}{\sigma_x \sigma_y} \quad (7.7)$$

onde, as médias e varianças são dadas por:

$$\mu_x = \sum_{i=0}^{n-1} i p_x(i) \quad \sigma_x^2 = \sum_{i=0}^{n-1} (i - \mu_x)^2 p_x(i)$$

$$\mu_y = \sum_{j=0}^{n-1} j p_y(j) \quad \sigma_y^2 = \sum_{j=0}^{n-1} (j - \mu_y)^2 p_y(j)$$

$$p_x(i) = \sum_{j=0}^{n-1} p(i, j) \quad p_y(i) = \sum_{i=0}^{n-1} p(i, j)$$

$$\text{Contraste} = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} (i - j)^2 p(i, j) \quad (7.8)$$

$$\text{Entropia} = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} p(i, j) \log_2 p(i, j) \quad (7.9)$$

$$\text{Soma_Entropia} = \sum_{k=0}^{2n-2} p_{x+y}(k) \log_2 [p_{x+y}(k)] \quad (7.10)$$

onde:

$$p_{x+y}(k) = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} p(i, j) \quad , \quad i+j = k \quad , \quad k=0, \dots, 2n-2$$

$$\text{Diferença_Entropia} = \sum_{k=0}^{2n-2} p_{x-y}(k) \log_2 [p_{x-y}(k)] \quad (7.11)$$

onde:

$$p_{x-y}(k) = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} p(i, j) \quad , \quad |i - j| = k \quad , \quad k=0, \dots, n-1$$

$$\text{MDI} = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} \frac{1}{1 + (i - j)^2} p(i, j) \quad (7.12)$$

$$\text{Média_Soma} = \sum_{k=0}^{2n-2} k p_{x+y}(k) \quad (7.13)$$

$$Variança_Soma = \sum_{k=0}^{2n-2} (k - média_soma)^2 p_{x+y}(k) \quad (7.14)$$

$$Média_Diferença = \sum_{k=0}^{n-1} k p_{x-y}(k) \quad (7.15)$$

$$Variança_Diferença = \sum_{k=0}^{n-1} (k - média_diferença)^2 p_{x-y}(k) \quad (7.16)$$

$$Energia = \sum_{k=0}^{n-1} p(k)^2 \quad (7.17)$$

$$MIC_1 = \frac{Entropia - H_1}{\max[H_X, H_Y]} \quad (7.18)$$

$$MIC_2 = (1 - \exp[-2(H_2 - H_{XY})])^{1/2} \quad (7.19)$$

onde:

$$H_X = - \sum_{i=0}^{n-1} p_x(i, j) \log_2[p_x(i)]$$

$$H_Y = - \sum_{j=0}^{n-1} p_y(i, j) \log_2[p_y(j)]$$

$$H_1 = - \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} p(i, j) \log_2[p_x(i) \cdot p_y(j)]$$

$$H_2 = - \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} p_x(i) \cdot p_y(j) \cdot \log_2[p_x(i) \cdot p_y(j)]$$

7.4 Atributos de momento de Hu

Hu (1962) apresentou sete momentos, que são extraídos do histograma de níveis de cinza, de segunda e terceira ordem de momentos centrada na média. Eles são invariantes a escala, posição e orientação. Em imagens em nível de cinza, fornecem informações de forma e distribuição de intensidade na imagem. A seguir, são apresentados os 7 descritores de Hu.

$$M_1 = \mu_{20} + \mu_{02}$$

(7.20)

$$M_2 = (\mu_{20} + \mu_{02})^2 + 4\mu_{11} \quad (7.21)$$

$$M_3 = (\mu_{30} - 3\mu_{12})^2 + (3\mu_{21} - \mu_{03})^2 \quad (7.22)$$

$$M_4 = (\mu_{30} + \mu_{12})^2 + (\mu_{21} + \mu_{03})^2 \quad (7.23)$$

$$M_5 = (\mu_{30} - 3\mu_{12})(\mu_{30} + \mu_{12})[(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2] + \\ + (3\mu_{21} - \mu_{03})(\mu_{21} + \mu_{03})[(3\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2] \quad (7.24)$$

$$M_6 = (\mu_{20} - \mu_{02}) [(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2] + \\ + 4\mu_{11} (\mu_{30} + \mu_{12})(\mu_{21} + \mu_{03})(\mu_{21} + \mu_{03}) \quad (7.25)$$

$$M_7 = (3\mu_{31} - \mu_{03}) (\mu_{30} + \mu_{12})^2 [(\mu_{30} + \mu_{12})^2] - (\mu_{21} + \mu_{03})^2] - \\ - (\mu_{30} - 3\mu_{12}) (\mu_{21} + \mu_{03}) [3(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2] \quad (7.26)$$

onde, $\mu_{00} = m_{00} = \mu$

$$\mu_{10} = \mu_{01} = 0$$

$$\mu_{20} = \mu_{20} - \mu_{10}$$

$$\mu_{11} = \mu_{11} - \mu \bar{X} \bar{Y}$$

$$\mu_{02} = \mu_{02} - \mu \bar{Y}^2$$

$$\mu_{30} = \mu_{30} - 3\mu_{20} \bar{X} + 2\mu \bar{X}^3$$

$$\mu_{21} = \mu_{21} - \mu_{20} \bar{Y} - 2\mu_{11} \bar{X} + 2\mu \bar{X}^2 \bar{Y}$$

$$\mu_{12} = \mu_{12} - \mu_{02} \bar{X} - 2\mu_{11} \bar{Y} + 2\mu \bar{X} \bar{Y}^2$$

$$\mu_{03} = \mu_{03} - 3\mu_{02} \bar{Y} + 2\mu_{11} \bar{Y}^3 + 2\mu \bar{X} \bar{Y}^2$$

Os descritores de Hu não são independentes do contraste do objeto, e são numericamente sensíveis a erros de arredondamento (El-Faramawy et al., 1996), por isso, cuidados foram tomados na normalização dos valores deste atributo.

7.5 Atributos de momentos estatísticos do histograma da imagem

O histograma da imagem é amplamente adotado como fonte de descrição de textura através de momentos devido à sua simplicidade de implementação. Porém, essa medida não fornece informações de distribuição dos valores de intensidade na imagem. Foram extraídos os seguintes momentos, centrados na média, das regiões de interesse da mama: média, desvio-padrão, momento de terceira ordem (*skewness*), e momento de quarta ordem (*kurtosis*). Foi extraído, também, o valor de entropia do histograma.

A equação da média é dada por:

$$\mu = \sum_{i=0}^{L-1} z_i \cdot p(z_i) \quad (7.27)$$

onde, z_i é a intensidade discreta da imagem, $p(z_i)$ o histograma normalizado da imagem, L o número de níveis de cinza da imagem.

O desvio-padrão, ou momento de segunda ordem, fornece o espalhamento em torno da média. É calculado por:

$$\sigma = \sqrt{\sum_{i=0}^{L-1} (z_i - \mu)^2 \cdot p(z_i)} \quad (7.28)$$

O momento de terceira (*skewness*) fornece o grau de simetria no histograma, e o de quarta ordem (*kurtosis*), o grau de achatamento da distribuição do histograma. Eles são calculados pelas equações:

$$S = \frac{\sum_{i=0}^{L-1} (z_i - \mu)^3 \cdot p(z_i)}{\sigma^3} \quad (7.29)$$

$$K = \frac{\sum_{i=0}^{L-1} (z_i - \mu)^4 \cdot p(z_i)}{\sigma^4} \quad (7.30)$$

A entropia serve para representar o espalhamento de intensidade no histograma. Se a distribuição é uniforme, então a entropia será máxima;

caso contrário, se a distribuição se restringir a uma faixa pequena do histograma, a entropia será mínima. A equação da entropia do histograma é dada por:

$$E = \sum_{i=0}^{L-1} p(z_i) \cdot \log_2[1 + p(z_i)] \quad (7.31)$$

A tabela 7.3 apresenta os valores dos momentos e da entropia calculados das imagens da figura 5.1.

TABELA 7.3: Valores de atributos de momentos estatísticos dos histogramas das imagens da figura 5.1.

	Média	Desvio-padrão	Skewness	Kurtosis	Entropia
Imagem (a)	58,7683	16,4751	-0,6134	2,3132	0,0503
Imagem (b)	90,6958	54,2807	0,4507	2,6233	0,0187
Imagem (c)	98,2805	52,8325	-0,0340	2,1339	0,0245
Imagem (d)	190,3751	67,5484	-1,5666	4,1011	0,0373

7.6 Medida de granulometria como atributo de textura

A Granulometria é uma área de conhecimento que, dentre outras coisas, trata da determinação da distribuição dos tamanhos de objetos em uma amostra. Esse conceito foi introduzido por Dougherty et al. (1992). Para determinação da distribuição, são aplicados filtros morfológicos de "abertura" com elemento estruturante de tamanho crescente na imagem original. A diferença entre a imagem original e a imagem filtrada é computada a cada passagem do elemento estruturante. No final do processo, essas diferenças são normalizadas e usadas na construção de um histograma de distribuição dos tamanhos das partículas (Gonzalez & Woods, 2000, 2001).

Na mamografia, a densidade comumente aparece com o aspecto granular, com tamanhos variados e espalhados na região da mama. Essa

característica pode ser utilizada como medida de Granulometria.

Em nosso trabalho, foram utilizadas as imagens com a região de tecidos fibro-glandulares segmentada, e foi aplicada a operação morfológica de abertura, com elemento estruturante de formato circular, e raio variando entre 5 e 60 pixels. Foi utilizado o histograma de distribuição dos tamanhos de objetos como atributo de medida de Granulometria. Na figura 7.4, é mostrada uma imagem de mamografia original e a região de tecidos fibro-glandulares segmentada. É mostrada, também, uma imagem numa das etapas da filtragem de abertura e o histograma de número de pixels em função do raio de abertura morfológico aplicado.

7.7 Extração de atributos no domínio de Radon

Gonzalez & Woods (2000,2001) definem as características importantes da abordagem espectral para análise direcional de textura:

- (1) picos proeminentes no espectro fornecem a direção dos padrões de textura;
- (2) a posição dos picos no plano da frequência fornece o período espacial fundamental dos padrões; e
- (3) a eliminação de quaisquer componentes periódicos através de filtragem deixa os elementos não periódicos na imagem, que podem ser descritos por técnicas estatísticas.

Essas características, também, são encontradas no domínio da transformada de Radon. Neste domínio, os valores de $R(t, \theta)$ apresentam picos provenientes de altas intensidades numa direção da imagem. A posição e orientação destes picos são facilmente identificadas (veja as seções 6.2 e 6.5).

FIGURA 7.4: Processo de extração de atributo de medida de Granulometria. (a) imagem original; (b) imagem com a região de tecido fibro-glandular segmentada; (c) imagem numa etapa de filtragem de abertura morfológica; (d) o histograma da quantidade de pixels em função do raio de abertura do elemento estruturante.

Podemos separar a função $R(t, \theta)$ em duas funções unidimensionais, $R_\theta(t)$ e $R_t(\theta)$, de acordo com características a serem extraídas da imagem. Por exemplo, se o interesse é obter as direções em que estão presentes as altas densidades na mama, podemos selecionar dentro do domínio de Radon, os pontos de intensidade máxima. Podemos então definir duas funções relacionadas $R_\theta(t)$ e $R_t(\theta)$. Os gráficos da figura 7.5 mostram o comportamento de duas funções em imagens mamográficas.

Para analisar o comportamento das funções $R_\theta(t)$ e $R_t(\theta)$, foram extraídos os valores da média, dos momentos centrada na média, e a entropia.

O valor da média foi dado por:

$$\mu_t = \sum_{i=0}^{179} \theta_i \cdot R_t(\theta_i) \quad (7.32)$$

$$\mu_\theta = \sum_{i=-m}^m t_i \cdot R_\theta(t_i) \quad (7.33)$$

onde, $R_t(\theta_i)$ é a intensidade máxima na direção do ângulo θ_i e $R_\theta(t_i)$ é o pico de intensidade na posição t_i . $[-m ; m]$ são os limites de t no domínio de Radon. O valor de m é obtido multiplicando-se o lado da matriz de pixels da imagem por $\sqrt{2}$.

Os momentos de segunda ordem ou variância são calculados por:

$$\sigma_t = \sum_{i=0}^{179} (\theta_i - \mu_\theta)^2 R_t(\theta_i) \quad (7.34)$$

$$\sigma_\theta = \sum_{i=-m}^{+m} (t_i - \mu_\theta)^2 R_\theta(t_i) \quad (7.35)$$

Os momentos de terceira ordem ou *skewness* são calculados por:

$$S_t = \frac{\sum_{i=0}^{179} (\theta_i - \mu_\theta)^3 R_t(\theta_i)}{\sigma^3} \quad (7.36)$$

$$S_\theta = \frac{\sum_{i=-m}^{+m} (t_i - \mu_\theta)^3 R_\theta(t_i)}{\sigma^3} \quad (7.37)$$

Os momentos de quarta ordem ou *kurtosis* são calculados por:

$$K_t = \frac{\sum_{i=0}^{179} (\theta_i - \mu_\theta)^4 R_t(\theta_i)}{\sigma^4} \quad (7.36)$$

$$K_\theta = \frac{\sum_{i=-m}^{+m} (t_i - \mu_\theta)^4 R_\theta(t_i)}{\sigma^4} \quad (7.37)$$

Os cálculos das entropias são obtidos por:

$$E_t = \sum_{i=1}^{179} R_t(\theta_i) \cdot \log_2 [1 + R_t(\theta_i)] \quad (7.38)$$

$$E_\theta = \sum_{i=-m}^{+m} R_\theta(t_i) \cdot \log_2 [1 + R_\theta(t_i)] \quad (7.39)$$

A figura 7.5 mostra a mesma imagem da figura 7.4 com a região fibro-glandular segmentada, os gráficos do domínio de Radon $R(t, \theta)$, e as funções decompostas $R_\theta(t)$ e $R_t(\theta)$. A tabela 7.4 apresenta os valores dos atributos extraídos dos gráficos $R_\theta(t)$ e $R_t(\theta)$ da figura 7.5.

FIGURA 7.5: Gráfico das funções de decomposição do domínio de Radon. (a) imagem da figura 6.7 com a região fibro-glandular segmentada; (b) Domínio de Radon $R(t, \theta)$; (c-d) as funções decompostas $R_t(\theta)$ e $R_\theta(t)$, respectivamente, do domínio de Radon.

TABELA 7.4: Medidas de momentos estatísticos extraídos dos gráficos $R_l(\theta)$ e $R_\theta(t)$ da figura 7.4.

Função	Média	Variança	Skewness	Kurtosis	Entropia
$R_l(\theta)$	85,9352	53,2773	0,1314	1,7293	0,0082
$R_\theta(t)$	17,3467	218,5510	-0,0306	2,6100	0,0018

Capítulo 8

Processo de seleção de atributos e recuperação das imagens.

Nesta etapa, os atributos extraídos das imagens mamográficas foram submetidos ao processo de seleção, classificação e comparação por similaridade.

O processo de seleção definiu a combinação de atributos que irão compor o conjunto de vetores de entrada para o treinamento e teste do classificador. Como o número de atributos da combinação variou entre 10 e 88, dependendo da combinação adotada, a alta dimensionalidade, em comparação ao número de amostras de treinamento e teste, ocasionou a adoção de uma técnica de redução dessa dimensionalidade na entrada do classificador. O método escolhido foi o método de análise de componentes principais (PCA) (Bishop, 1995). O classificador utilizado foi a Rede de Mapas Auto-Organizáveis de Kohonen (SOM). O agrupamento das amostras de treinamento e teste, aplicado nesta etapa, também foi escolhido adequadamente para garantir um alto grau de generalização da rede neural. Para isso, a técnica escolhida foi o "leaving-one-out".

A comparação entre a imagem de teste (consulta) e as imagens do mesmo grupo de classe, foram feitas através de uma técnica de alinhamento das imagens e uma medida de similaridade.

8.1 Seleção de Atributos

O objetivo principal de nossa pesquisa é investigar as características de cada grupo de atributos na detecção de similaridades de densidade de tecidos entre os mamogramas digitalizados. Neste sentido, foram realizadas 36 combinações entre os grupos de atributos para a investigação de cada conjunto de entrada do classificador. Os agrupamentos de atributos foram obtidos realizando combinações simples de 1, 2, 3, 4 e 5 atributos, totalizando 31 conjuntos. O grupo de atributo de forma ficou de fora do cálculo das combinações, mas fez parte de todos os 31 conjuntos de atributos. Foram acrescentados, ainda, 5 conjuntos para cada grupo de atributos individualmente, sem o grupo de atributos de forma. No total foram investigados 36 conjuntos de atributos.

8.1.1 Normalização dos valores de atributos

Antes da redução da dimensão da matriz de entrada do classificador, os dados foram normalizados para ter média zero e desvio-padrão igual à unidade, através da seguinte transformação:

$$\bar{x} = \frac{x - \mu}{\sigma} \quad (8.1)$$

onde x é o valor do atributo, $\bar{x}$ é o valor normalizado, μ e σ são a média e desvio-padrão, respectivamente. Este procedimento foi realizado para que um conjunto de dados não se torne dominante sobre outro na classificação. Os valores com esta transformação foram normalizados para o intervalo $[-1, 1]$.

Para a entrada do classificador, após a redução da dimensionalidade dos dados, os valores foram normalizados novamente para estarem no intervalo de $[0, 1]$. Para isso, foi aplicada a seguinte equação:

$$\bar{x} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (8.2)$$

onde, x_{min} e x_{max} são os valores respectivos de mínimo e máximo do conjunto de valores de atributos.

8.1.2 Redução da dimensionalidade do conjunto de atributos

Para reduzir a dimensionalidade dos vetores de entrada do classificador, foi utilizada a técnica de análise de componentes principais (Bishop, 1995). Esse método, também conhecido como expansão de Karhunen-Loève, serve para descorrelacionar dados que apresentam certa dependência. Autovetores transformam dados originais em um novo grupo de dados não correlacionados e possuindo a máxima variância. Selecionamos autovetores contribuindo com 95% ou mais da variância total dos dados.

8.2 Definição dos grupos de amostras de treinamento e teste

Para definir os vetores de entrada da rede neural artificial auto-organizável (SOM), a amostra de dados das imagens foi dividida em grupo de treinamento e teste. Utilizamos a técnica "leaving-one-out" para selecionar as amostras. Neste método, numa amostra com n elementos, um elemento é deixado de fora do conjunto de treinamento e treina-se a rede com os outros $(n-1)$ elementos restantes. O elemento deixado de fora é, então, utilizado como teste para o treinamento realizado. Repete-se esse procedimento para todos os elementos da amostra. Com isso, os n elementos serão testados e também participarão na amostra de treinamento dos $(n-1)$ elementos restantes. A avaliação do grau de generalização do classificador ficou, desta forma, garantida com este método (Beale & Jackson, 1990).

A amostra da base de imagens utilizada era composta de 1.080 imagens divididas em 270 imagens CC esquerda, 270 imagens CC direita, 270 imagens MLO esquerda e 270 imagens MLO direita. Para os quatro grupos executou-se o treinamento com o método "leaving-one-out". Desta forma, para cada conjunto de atributos selecionados, executou-se 1.080 processos de treinamento e teste, totalizando 38.800 processos.

8.3 A rede neural de mapa auto-organizável de Kohonen na recuperação de imagens

Teuvo Kohonen, professor da Faculdade de Ciências da Informação, da Universidade de Helsinki, desenvolveu a rede neural de mapas auto-organizáveis (SOM). A rede assume uma estrutura topológica em forma de mapas espaciais formada por unidades de agrupamento. Cada unidade de agrupamento possui características similares de "funcionamento". Ou seja, unidades que estiverem próximas umas das outras responderão analogamente à entradas similares (Vicentini, 2002). Esta propriedade não é encontrada em outras estruturas de redes neurais artificiais.

8.3.1 Arquitetura da rede de mapas auto-organizáveis de Kohonen.

Na arquitetura SOM, os neurônios organizam-se em forma de grades, retangular ou hexagonal, e dispostos, geralmente, em camadas bidimensionais. A figura 8.1 apresenta a topologia da rede SOM e as grades com a vizinhança de um neurônio vencedor. Conforme Kohonen (1990), o esquema básico do modelo faz com que neurônios da camada de saída disputem entre si a representação da informação apresentada aos neurônios de entrada. Havendo um neurônio vencedor, este é reajustado para responder ainda mais ao estímulo recebido. Dentro deste modelo não supervisionado, não somente o vencedor, mas também os seus vizinhos são ajustados (Fauset, 1994).

Resumidamente, o mecanismo da rede SOM funciona da seguinte forma: aos pesos sinápticos, são atribuídos valores aleatórios e baixos. Um um sinal de entrada x (com valores que representam uma informação qualquer) é fornecido à rede sem que se especifique a saída desejada (treinamento não supervisionado). O sinal de entrada x é descrito como :

$$x = [x_1, x_2, \dots, x_n]$$

Dada uma entrada x_i , um neurônio de saída y_j deverá responder melhor à essa entrada, então, ele será considerado o vencedor. Isto faz com

que este neurônio seja disparado sempre que essa entrada específica for apresentada à rede neural. O neurônio vencedor y_j , e seus vizinhos $v\{y_j\}$, terão seus pesos sinápticos ajustados para responder melhor do que antes à entrada apresentada x_i . A rede é considerada treinada depois de todo o conjunto de treinamento ter sido apresentado à rede, e os critérios de treinamento terem sido satisfeitos. Seguindo a fase de treinamento, temos a fase de teste da rede neural. Essa fase é semelhante à fase de treinamento, só que não serão mais alterados os pesos dos neurônios. Para que o teste seja mais apurado, a rede poderá receber, como entrada, além das amostras que foram apresentadas, outras que não fizeram parte do conjunto de treinamento, chamada de ruído. Reconhecendo as entradas do teste de forma adequada a rede é considerada treinada com sucesso.

A adaptação dos neurônios é crucial para a formação ordenada do mapa, pois, apesar de um neurônio ser afetado independentemente do outro, é o conjunto inteiro que representa a informação (Kohonen, 1990). O ajuste dos pesos sinápticos acontece da seguinte forma, primeiro procura-se descobrir qual é o neurônio vencedor para a entrada apresentada, ou seja, qual é o neurônio que possui a menor distância. Normalmente, utiliza-se a distância Euclidiana :

$$d_i = \sqrt{\sum_{j=1}^n (w_j - x_i)^2} = \sum_{j=1}^n \|x - w_j\| \quad (8.3)$$

onde, x é o vetor de entrada e w_j é o vetor de pesos associado ao neurônio j . Em cada passo do aprendizado, o neurônio que melhor responder, deverá ser ajustado para responder ainda melhor àquela entrada, e, conjuntamente, todos os neurônios dentro da vizinhança V_j serão alterados. Os neurônios que estiverem fora do subconjunto de vizinhança não serão ajustados. A adaptação dos neurônios é muito simples. Uma vez escolhida a unidade vencedora, os pesos deste neurônio e seus vizinhos serão atualizados por

$$w_j(t+1) = \begin{cases} w_j(t) + \alpha(t)[x(t) - w_j(t)] & \text{se } j \in V_n(t) \\ w_j(t), & \text{se } j \notin V_n(t) \end{cases} \quad (8.4)$$

onde t é a etapa de iteração, V_n é a variação da vizinhança e $\alpha(t)$ é a taxa de aprendizagem.

Kohonen (1990) propõe que, na prática computacional, o processamento pode parar quando o termo chegar a zero, pois, automaticamente, não haverá mais alterações nos pesos do neurônio selecionado. O que tem sido feito também é estabelecer períodos de decremento diferentes para momentos diferentes de t durante o treinamento. Isso quer dizer que pode existir uma flutuação diferente em um tempo diferente dentro do mesmo treinamento.

O critério adotado para a parada do algoritmo de treinamento, pode ser através do número de iterações (epochs) escolhido ou da taxa de aprendizagem, normalmente, entre 0 e 1.

8.4 Os parâmetros adotados para a classificação das imagens

As imagens foram agrupadas em amostras de 270 imagens, sendo, para cada treinamento realizado, 269 imagens para o treinamento e 1 imagem de teste.

Usamos as funções disponíveis da biblioteca de ferramentas de redes neurais do MatLab®, versão 6.5, Release 13. Adotamos a topologia com 16 x 16 neurônios para a grade de saída, totalizando 256 neurônios na camada de saída. Para o treinamento, adotamos o valor máximo de 8.000 ciclos e a taxa de aprendizagem não foi fixada. Porém, em todas as configurações de dados de entrada da rede, taxa de aprendizagem não ultrapassou o valor de 0,0001.

FIGURA 8.1: Topologia da rede Som e as grades retangular e hexagonal de vizinhança de um neurônio vencedor.

8.5 Técnica de alinhamento entre as imagens

Para realizar a medida de similaridade entre a imagem teste e as outras imagens da mesma classe, foi realizado o alinhamento entre essas imagens.

Adotamos a posição do mamilo e a direção da parede torácica como referência para o alinhamento de imagens da vista CC. Para as imagens MLO, usamos a posição do mamilo e a direção da linha que separa a região do músculo peitoral.

Para a imagem da projeção CC, trasladou-se a imagem de tal forma

que o ponto de referência detectado do mamilo posicionasse no centro da imagem e a linha da parede torácica permanecesse paralela à direção vertical. Neste caso, a imagem foi ampliada em sua dimensão para realizar essa transformação espacial.

Para a imagem da projeção MLO, trasladou-se a imagem da mesma forma que a incidência CC, acrescentando-se, a essa, a transformação rotacional da direção do músculo peitoral com a direção vertical da imagem.

A imagem foi primeiramente ampliada com o acréscimo de 256 pixels em cada lado da imagem, formando uma matriz de 1536x1536 pixels. Esse procedimento se fez necessária para realizar as transformações espaciais e de rotação. Após executar o alinhamento, as imagens foram redimensionadas novamente para 1024x1024 pixels através de interpolação bi-linear. Desta forma, todas as imagens ficaram com a posição do mamilo numa mesma posição e a base da mama numa direção vertical, e mantiveram a razão de aspecto. A figura 8.3 apresenta duas imagens antes e após a transformação.

8.6 A medida de similaridade entre as imagens

A medida de similaridade foi realizada com o cálculo do coeficiente de correlação, que é definido por

$$cc(f, g) = \frac{\sum_x \sum_y [f(x, y) - \bar{f}][g(x, y) - \bar{g}]}{\left\{ \sum_x \sum_y [f(x, y) - \bar{f}]^2 [g(x, y) - \bar{g}]^2 \right\}^{1/2}} \quad (8.5)$$

para $(x, y) \in f \cap g$, sendo, $\bar{f}$ e $\bar{g}$ os valores médios dos pixels de f e g , respectivamente (Sonka & Patrick, 2000).

FIGURA 8.2: Transformação escalar e de rotação de imagens para alinhamento. (a) e (b) as imagens originais; (b) e (d) as imagens transformadas.

Capítulo 9

Resultados e Discussão

A apresentação dos resultados e discussão segue a seqüência de etapas apresentadas na proposta de metodologia: (1) etapa de base de imagens, preparação e processamento das imagens; (2) extração e seleção de atributos; (3) recuperação de imagens por rede de mapa auto-organizável de Kohonen (SOM).

9.1 Base de imagens, preparação e processamento das imagens

Esta etapa envolveu a preparação da imagem com a retirada de ruído, segmentação da região da mama, detecção da linha de separação da região do músculo peitoral, determinação da posição do mamilo e segmentação da região de tecido fibro-glandular.

9.1.1 Base de Imagens e preparação das imagens

As imagens utilizadas pertencem ao acervo do Hospital de Clínicas da Faculdade de Medicina de Ribeirão Preto (HCFMRP-USP), projeto de banco de imagens - Módulo Mamografia, aprovado pelo Comitê de Ética sob número 10093/2002. Esse reconhecimento oficializa a importância do banco de imagens do hospital como uma importante ferramenta de pesquisa na área de imagens. Essa base de imagens apresentou características importantes que eliminaram a adoção de outras bases disponíveis para pesquisa. Ela representou a realidade técnica de aquisição e digitalização

disponíveis no hospital que incentivou, de modo fundamental, a proposição de métodos de preparação das imagens antes do processo de análise e recuperação dessas imagens. As presenças de ruídos, artefatos e tamanhos diferentes de filmes mamográficos tornaram o trabalho de pesquisa mais oneroso, mas acreditamos que enriqueceu de modo significativo o trabalho proposto.

O processo de recorte da imagem foi satisfatório, pois manteve a razão de aspecto da imagem. Análises visuais foram feitas em todas as imagens para confirmar a retirada da identificação do paciente .

Neste processo, algumas imagens da base de imagens foram descartadas, pois com o recorte automático da região de identificação da paciente, parte da região da mama foi subtraída da imagem. Outras, de acordo com laudo médico, eram mamas submetidas à cirurgia e, portanto, sem parte de tecidos mamários. Mesmo assim, a amostra permaneceu com número de 1080 imagens.

9.1.2 Processo de retirada de ruído e restauração da borda

A aplicação da equação de Difusão Anisotrópica com filtro de Wiener nas imagens, mostrou-se mais eficaz na diminuição e suavização do ruído do que com filtros Morfológico ou Gaussiano. A tabela 9.1 apresenta o valor médio da Relação sinal-ruído (SNR) para cada aplicação dos filtros com a equação de Difusão Anisotrópica.

Foi medido o tempo computacional médio da aplicação da equação de Difusão Anisotrópica com cada um dos processos de filtragem. Para o filtro Morfológico foi de 32,1 segundos, para o filtro Gaussiano foi de 35,4 segundos, e para o filtro de Wiener foi de 25,0 segundos.

TABELA 9.1: Relação sinal-ruído (SNR) calculado para as três aplicações da equação de Difusão Anisotrópica com filtro morfológico de abertura e fechamento, filtro Gaussiano e filtro de Wiener.

# imagens por incidência	Difusão Anisotrópica com Filtro Morfológico	Difusão Anisotrópica com Filtro Gaussiano	Difusão Anisotrópica com Filtro Wiener
CCD (270)	15,23 dB	17,48 dB	20,51 dB
CCE (270)	16,60 dB	18,43 dB	21,26 dB
MLOD (270)	18,49 dB	19,98 dB	22,20 dB
MLOE (270)	18,96 dB	19,11 dB	21,57 dB
GERAL (1080)	17,32 dB	18,75 dB	21,38 dB

CCE: incidência crânio-caudal esquerda; CCD: incidência crânio-caudal direita; MLOD: incidência médio-lateral oblíqua direita; MLOE: incidência médio-lateral oblíqua esquerda

9.1.3 Processo de segmentação da região da mama

A primeira etapa do processo de segmentação correspondeu à seleção do limiar ótimo para a limiarização das imagens. Os métodos investigados foram: Princípio de Máxima Entropia (PME), Método de Preservação de Momento (MPM), Método de Otsu (OTSU), Método de Ridler & Carvard (RIDLER), Método da Matriz de Co-ocorrência (MMCO), Método de Reddi (REDDI 1 e REDDI 2).

A tabela 9.2 apresenta a quantidade de vezes em que cada técnica contribuiu com o limiar ótimo. Os melhores resultados obtidos foram com os métodos da matriz de co-ocorrência (MMCO) com uma porcentagem de 77,50%, seguidos dos métodos de preservação do momento (MPM) com 68,06% e o método de princípio de máxima entropia (PME) com 61,11%. Este resultado mostrou algumas características importantes dos métodos empregados. Como vimos, o método de limiarização busca picos ou vales no histograma. Os métodos que buscaram os valores de picos do histograma tiveram melhor performance na determinação do limiar ótimo. A

figura 9.1 apresenta duas imagens e seus respectivos histogramas. O pico no histograma é causado pela presença de ruído suavizado no fundo da imagem. No caso do método MMCO, a determinação do histograma a partir da matriz de co-ocorrência, que leva em consideração a vizinhança entre intensidades, foi fundamental para o seu melhor resultado. Em análise mais específica, foi verificado que os outros métodos, OTSU, RIDLER e REDDI, tiveram alguma eficácia em imagens com histograma com características bimodais, mas no geral, não tiveram bom desempenho. O tempo de processamento desta rotina ficou em torno de 2,8 segundos.

Como o processo de segmentação é fundamental para a sequência de preparação da imagem, foi adotado o limiar ótimo, selecionado pelo radiologista especialista, para a segmentação das imagens e não simplesmente o melhor método.

A aplicação da interpolação b_3 -spline teve resultados inaceitáveis somente em 28 imagens, devido à presença de ruído suavizado na base da mama e a indefinição dos limites do contorno da mama.

A avaliação da segmentação levou em consideração a preservação da borda real da mama e considerou inaceitável nos casos em que houve supressão de tecidos da mama ou acréscimo excessivo de tecidos inexistente na mama real. A avaliação indicou para a incidência crânio-caudal (CC) que 7 (1,30%) imagens foram inaceitáveis, 156 (28,89%) aceitáveis e 377 (69,81%) exatas. Para a incidência médio-lateral oblíqua (MLO), a avaliação de restauração indicou que 21 (3,89%) foram inaceitáveis, 154 (28,52%) aceitáveis e 365 (67,59%) exatas.

A figura 9.2 mostra um exemplo em que a segmentação foi considerada exata nas duas incidências. A figura 9.3 mostra outro exemplo em que a segmentação foi considerada exata na incidência CC e aceitável na incidência MLO. A figura 9.4 mostra um exemplo em que a segmentação foi considerada inaceitável nas duas incidências.

TABELA 9.2: Relação da quantidade e porcentagem de limiar ótimo escolhido para os métodos de segmentação da região da mama.

# imagens por incidência	PME	MPM	OTSU	RIDLER	MMCO	REDDI 1	REDDI 2
CCD (270)	194 (71,85%)	201 (74,44%)	0 (0,00%)	11 (4,07%)	237 (87,78%)	9 (3,33%)	1 (0,37%)
CCE (270)	183 (67,78%)	164 (60,74%)	4 (1,48%)	8 (2,96%)	187 (69,26%)	19 (7,04%)	21 (7,78%)
MLD (270)	138 (51,11%)	181 (67,04%)	0 (0,00%)	2 (0,74%)	207 (76,67%)	10 (3,70%)	1 (0,37%)
MLE (270)	145 (53,70%)	189 (70,00%)	0 (0,00%)	0 (0,00%)	206 (76,30%)	7 (2,59%)	6 (2,22%)
Total (1080)	660 (61,11%)	735 (68,06%)	4 (0,37%)	21 (1,94%)	837 (77,50%)	45 (4,17%)	29 (2,69%)

CCE: incidência crânio-caudal esquerda; CCD: incidência crânio-caudal direita; MLOD: incidência médio-lateral oblíqua direita; MLOE: incidência médio-lateral oblíqua esquerda

FIGURA 9.1: (a) Imagem da incidência CC e o histograma correspondente abaixo; (b) imagem da incidência MLO e o histograma correspondente

FIGURA 9.2: Imagens da etapa de restauração da borda e segmentação. (a) e (d) imagem original; (b) e (e) aplicação da equação de Difusão Anisotrópica com o filtro de Wiener. (c) e (f) processos de segmentação

FIGURA 9.3: Imagens da etapa de restauração da borda e segmentação. (a) e (d) imagem original; (b) e (e) após a aplicação da equação de Difusão Anisotrópica com o filtro de Wiener, (c) processo de segmentação considerada exata, (d) processo de segmentação considerada aceitável.

FIGURA 9.4: Imagens da etapa de restauração da borda e segmentação. (a) e (d) imagem original; (b) e (e) após a aplicação da equação de Difusão Anisotrópica com o filtro de Wiener, (c) e (f) processos de segmentação consideradas inaceitáveis.

9.1.4 Processo de detecção da linha da região do músculo peitoral

Como foi descrito na seção 6.2, o detector de borda de Canny varia com o valor de desvio-padrão σ . E a detecção da linha que separa essa região pela transformada de Radon está diretamente relacionada com a detecção da borda dessa região. Portanto, a definição de σ foi fundamental nesta etapa. Para isso, foi realizado, a partir do valor do Erro médio quadrático (E_{RMS}) entre as linhas detectadas de modo manual e automático, os seguintes levantamentos:

Foi computado o número de imagens por categoria de acordo com o critério descrito na seção 6.3. Esses valores foram compilados para as imagens MLO esquerda, direita e em conjunto. As figuras 9.5, 9.6 e 9.7 apresentam os gráficos do número de imagens em função da categoria de

avaliação da detecção para as imagens MLO direita, esquerda e em conjunto, respectivamente. Foi computado, também, o valor médio de E_{RMS} para as imagens MLO direita, esquerda e em conjunto. A figura 9.6 apresenta o gráfico dos valores médios em função do desvio-padrão σ aplicado no filtro de Canny.

Os gráficos das figuras 9.5, 9.6 e 9.7 mostram que o número de imagens por categoria variou de acordo com σ . Os melhores resultados obtidos foram para $\sigma = 6, 7, 8, 9$ e 10 .

Para definir qual valor de σ adotar, foi analisado o gráfico da figura 9.8. Os melhores resultados obtidos, considerando as duas incidências, foram para $\sigma = 8, 9$ e 10 . Foi escolhido o menor valor da média de E_{RMS} que foi de $9,81\text{ mm}$ para $\sigma = 8$.

Em algumas imagens, a detecção da linha peitoral não foi bem sucedida, devido aos seguintes problemas: baixo contraste entre o tecido muscular do peitoral com a do tecido mamário próximo a essa região; contorno irregular da região peitoral que dificultou a detecção automática da linha peitoral; presença de tecido muscular no prolongamento inferior da base da mama, próximo à parede torácica, que interferiu na direção da linha reta detectada pelo algoritmo. A figura 9.9 mostra um exemplo em que o baixo contraste entre o tecido muscular e o tecido fibro-glandular interferiu na detecção da linha peitoral.

O tempo de processamento do filtro de Canny foi de $58,9$ segundos e da transformada de Radon foi de $2,4$ segundos. O tempo total considerando outras rotinas complementares utilizadas na detecção da linha do músculo peitoral, foi de $61,8$ segundos. Relativamente, o custo computacional do filtro de Canny foi considerado alto, apesar do bom resultado alcançado.

FIGURA 9.5: Gráfico do número de imagens da incidência MLO direita em função do erro médio quadrático (E_{RMS}) entre a linha peitoral detectada de modo automático e manual. σ corresponde ao desvio-padrão do filtro de Canny.

FIGURA 9.6: Gráfico do número de imagens da incidência MLO esquerda em função do erro médio quadrático (E_{RMS}) entre a linha peitoral detectada de modo automático e manual. σ corresponde ao desvio-padrão do filtro de Canny.

FIGURA 9.7: Gráfico do número de imagens da incidência MLO direita e esquerda em função do erro médio quadrático (E_{RMS}) entre a linha peitoral detectada de modo automático e manual. σ corresponde ao desvio-padrão do filtro de Canny.

FIGURA 9.8: Gráfico do valor médio do erro médio quadrático (E_{RMS}), em milímetro, entre a linha peitoral detectada de modo automático e manual em função do desvio-padrão σ do filtro de Canny das imagens da incidência MLO esquerda e direita juntas.

FIGURA 9.9: Imagem com exemplo de detecção errada da linha de músculo peitoral. (a) imagem original; (b) após a aplicação do detector de borda de Canny; (c) as linhas retas candidatas detectadas pela transformada de Radon; (d) a linha selecionada automaticamente (maior inclinação) e a definida manualmente (menor inclinação).

9.1.5 Processo de detecção do mamilo

A quantidade e porcentagem de imagens, em função da faixa de erro entre a detecção manual e automática, são apresentadas na tabela 9.3. A porcentagem é calculada sobre o número total de imagens em cada incidência analisada. Foi calculado, também, o valor médio de E_{RMS} em cada incidência e distribuída pela faixa de erro detectado. O resultado é apresentado na tabela 9.4.

A tabela 9.3 indica que, no geral, o processo de detecção falhou em apenas 77 imagens (7,13%) do total. O número de imagens com detecção considerada excelente somada ao considerado como bom, foi de 856, correspondendo a 79,26% das imagens. Esse número puxou a média geral

de erro para a faixa de 7,39 mm (tabela 9.4). A figura 9.10 mostra quatro imagens e a taxa de E_{RMS} calculada para cada imagem. As imagens tiveram valor de E_{RMS} iguais a 24,12 mm, 9,80 mm, 7,81 mm e 0,95 mm, respectivamente. Como a média obtida foi de 7,39 mm, a imagem (c) com 7,81 mm, ilustra a dimensão da média obtida em nosso método. O tempo médio de processamento deste processo foi de 54,9 segundos.

9.1.6 Processo de segmentação da região de tecidos fibro-glandulares

A técnica escolhida para segmentação da região fibro-glandular das imagens mamográficas, foi escolhida visualmente com supervisão de um radiologista. Foram utilizadas as técnicas de Princípio de Máxima Entropia (PME), Método de Preservação de Momento (MPM), e o Método de Otsu (OTSU). A tabela 9.5 fornece a quantidade de vezes que cada técnica contribuiu com o limiar ótimo selecionado. O método de Otsu teve melhor desempenho em imagens da incidência crânio-caudal (CC), enquanto o Método de Preservação de Momento em imagens da incidência médio-lateral oblíqua (MLO). A característica bi-modal da distribuição do histograma para a imagem da incidência CC favoreceu a determinação do limiar ótimo da técnica de Otsu, enquanto a distribuição não bi-modal do histograma favoreceu o Método de Preservação de Momento. A figura 9.11 ilustra o histograma de uma imagem da incidência CC e outra MLO.

Escolhemos, também, neste caso, o limiar ótimo alcançado pelos três métodos e não simplesmente um método específico, pois a qualidade do processo de segmentação da região fibro-glandular pode interferir no processo de extração de atributos.

O tempo total de processamento deste processo, incluindo os três métodos de segmentação, foi de 2,5 segundos.

TABELA 9.3: quantidade e porcentagem de imagens por categoria de faixa de erro médio quadrático (E_{RMS}).

# imagens/ Incidência	Erro médio quadrático (E_{RMS})				
	≤ 5 mm	≤ 10 mm	≤ 15 mm	≤ 20 mm	>20 mm
CCD (270)	157 (58,15%)	67 (24,82%)	22 (8,15%)	14 (5,18%)	10 (3,70%)
CCE (270)	168 (62,22%)	72 (26,67%)	14 (5,19%)	7 (2,59%)	9 (3,33%)
MLOD (270)	146 (54,07%)	52 (19,26%)	27 (10,00)%	16 (5,93%)	29 (10,74%)
MLOE (270)	114 (42,22%)	80 (29,63%)	27 (10,00%)	20 (7,41%)	29 (10,74%)
GERAL (1080)	585 (54,17%)	271 (25,09%)	90 (8,33%)	57 (5,28%)	77 (7,13%)

TABELA 9.4: Valores médios de E_{RMS} em função da incidência das imagens CC direita, CC esquerda, MLO direita, MLO esquerda e o conjunto de todas as incidências.

	CCD	CCE	MLOD	MLOE	GERAL
Valor Médio (mm)	6,45	5,44	8,04	9,64	7,39

9.1.7 Considerações finais da etapa

Os métodos apresentaram bons resultados finais e deixaram as imagens em condições para a próxima etapa de extração e seleção de atributos. O tempo total desta etapa foi de 172,2 segundos. Este tempo deve ser considerado numa aplicação dentro da rotina do serviço de radiologia. Os maiores tempos consumidos, foram na detecção da linha da região do músculo peitoral e na detecção do mamilo, que juntas consumiram 116,7 segundos, ou seja, quase 77,0% do tempo total.

FIGURA 9.10: Erro raiz média quadrática (E_{RMS}) da detecção do mamilo para quatro imagens. (a) $E_{RMS} = 24,12$ mm; (b) $E_{RMS} = 9,80$ mm; (c) $E_{RMS} = 7,81$ mm; (d) $E_{RMS} = 0,95$ mm. O E_{RMS} corresponde distância entre os dois pontos brilhantes na imagem.

TABELA 9.5: Relação da quantidade e porcentagem de limiar ótimo escolhido para os métodos de segmentação da região fibro-glandular.

Incidência	PME	MPM	OTSU
CCD	9 (3,33%)	91 (33,70%)	178 (65,93%)
CCE	11 (4,07%)	93 (34,44%)	177 (65,56%)
MLOD	2 (0,74%)	205 (75,93%)	67 (24,81%)
MLOE	1 (0,37%)	201 (74,44%)	70 (25,93%)
GERAL	23 (2,13%)	590 (54,63%)	492 (45,56%)

CCE: incidência crânio-caudal esquerda; CCD: incidência crânio-caudal direita; MLOD: incidência médio-lateral oblíqua direita; MLOE: incidência médio-lateral oblíqua esquerda

FIGURA 9.11: imagem preparada para a etapa de segmentação da região fibro-glandular (a) Imagem da incidência CC e o histograma correspondente abaixo: (b) imagem da incidência MLO e o histograma

9.2 Extração e seleção de atributos visuais

Após o processo de extração, foi feita a seleção dos atributos para a classificação. Como o número de atributos variou de 10 a 88, de acordo com a combinação dos grupos, houve necessidade da redução da dimensionalidade e da redundância de dados. A tabela 9.6 relaciona a redução da dimensionalidade realizada pelo algoritmo de Análise de Componentes Principais (PCA).

Os tempos de processamento para esta etapa variaram bastante. Para a determinação das regiões de interesse foi em torno de 1,0 segundo, porém, para a extração dos atributos, a variação foi bastante significativa: para atributos de forma foi de 1,6 segundos, para atributos de textura de Haralick foi de 3,5 segundos, para atributos de Momento de Hu foi de 5,5 segundos, para atributo de Momento estatístico de histograma foi de 0,3

segundos, para atributos de medida de Granulometria foi de 174,9 segundos e para atributo espectrais no domínio de Radon foi de 12,9 segundos.

O custo computacional da extração do atributo de Granulometria foi alto, devido às rotinas de TopHat e de Abertura morfológica utilizadas.

TABELA 9.6: Relação da redução da dimensionalidade de atributos pelo algoritmo de Análise de Componentes Principais (PCA).

Combinação de grupos de Atributos	Número de Atributos	Redução da dimensão	Combinação	Número de Atributos	Redução da dimensão
H	10	8	F,M,G	30	13
T	28	8	F,R,G	36	17
M	14	7	F,H,T,M	55	15
R	20	13	F,H,T,R	61	17
G	13	9	F,H,T,G	54	16
F,H	13	10	F,H,M,R	47	16
F,T	31	9	F,H,M,G	40	17
F,M	17	8	F,H,R,G	46	18
F,R	23	14	F,T,M,R	65	17
F,G	16	11	F,T,M,G	58	14
F,H,T	41	13	F,T,R,G	64	17
F,H,M	27	14	F,M,R,G	50	19
F,H,R	33	16	F,H,T,M,R	75	18
F,H,G	26	15	F,H,T,M,G	68	17
F,T,M	45	12	F,H,M,R,G	60	18
F,T,R	51	16	F,H,T,R,G	74	18
F,T,G	44	13	F,T,M,R,G	78	18
F,M,R	37	15	F,H,T,M,R,G	88	18

F: forma; T: textura de Haralick; M: momento de Hu; H: momento de Histograma; R: domínio de Radon ;G: granulometria

9.3 A imagens recuperadas e a comparação por similaridade

Pela proposta de recuperação baseada em conteúdo proposta no trabalho, as imagens recuperadas são obtidas a partir de uma imagem de

teste aplicada à entrada de uma rede SOM e treinada com um conjunto de imagens. O tempo médio de processamento para treinamento e teste da rede SOM foi de aproximadamente 62,6 segundos.

Para avaliar o desempenho desse processo foram calculadas: (1) a taxa de precisão da classificação da composição dos tecidos pelo critério BI-RADS registrada no laudo médico dos pacientes; (2) a precisão e revocação (*precision and recall*) de acordo com a faixa de limiar (0.1 a 0.9) do valor médio do coeficiente de correlação.

9.3.1 Avaliação pela classificação da composição dos tecidos

A classificação foi realizada levando em consideração a avaliação descrita no laudo médico e a variabilidade existente entre observadores (Schmidt, 1998). A figura 9.12 mostra um exemplo em que uma imagem teste (consulta) e as imagens recuperadas têm classificações de composição diferentes. A imagem de consulta foi classificada como de composição 4, enquanto as imagens recuperadas foram classificadas como de composição 2 ou 3, apesar de que, visualmente, as imagens apresentam padrões de distribuição e quantidade muito próximos. A variabilidade da classificação levou-nos a adotar um critério que a levasse em consideração. Consideramos corretas imagens recuperadas com composições vizinhas à imagem teste. A tabela 9.7 mostra o critério adotado pelas faixas de composições vizinhas.

A avaliação foi feita para cada grupo de atributos e as combinações entre os grupos de atributos, conforme a tabela 9.6. Os resultados foram apresentados separados em quatro grupos (CC direita, CC esquerda, MLO direita e MLO esquerda), porém na avaliação final considerou-se apenas o resultado geral com todas as incidências. As figuras 9.13, 9.14, 9.15, 9.16, 9.17 e 9.18 apresentam os gráficos da taxa média de precisão para as combinações adotadas.

FIGURA 9.12: Imagens recuperadas com o atributo espectral no domínio de Radon. Em (a) a imagem teste com composição 4, classificadas no padrão BI-RADS; em (b) imagem recuperada com composição 2; em (c) imagem recuperada com composição 3; e (d) imagem recuperada com composição 2.

TABELA 9.7: Tabela do critério usado na classificação das imagens recuperadas considerando a variabilidade ocorrida durante a avaliação da imagem de acordo com a composição no padrão BI-RADS.

Composição da imagem teste	Faixa de classes consideradas pela composição de tecidos na classificação
1	1 e 2
2	1, 2 e 3
3	2, 3 e 4
4	3 e 4

Os melhores resultados obtidos para cada combinação são apresentados na tabela 9.8. Note que o grupo de atributos estatísticos extraídos do histograma participou em todas as combinações das configurações com os melhores resultados. A causa disso é que a classificação pela composição não leva em consideração a localização em dos tecidos ao longo da mama. A taxa de precisão de todas as combinações se manteve num patamar acima de 80%. A taxa mínima obtida para 1 grupo de atributos foi de 81,34%; para 2 grupos de atributos foi de 81,08%; para 3 grupos de atributos foi de 81,65%; para 4 grupos de atributos foi de 84,42% e para 5 grupos de atributos foi de 87,24%.

O Coeficiente de Correlação médio e o desvio-padrão obtido para os melhores resultados foram, respectivamente, de: $0,8301 \pm 0,1129$, $0,8453 \pm 0,0975$, $0,8491 \pm 0,0901$, $0,8495 \pm 0,0952$, $0,8563 \pm 0,0868$ e $0,8490 \pm 0,0986$. Esses resultados demonstraram uma alta correlação entre as imagens recuperadas e a imagem teste.

TABELA 9.8: Os melhores resultados obtidos pela classificação da composição dos tecidos, de acordo com o padrão BI-RADS, para cada combinação de atributos.

Taxa de Precisão	Grupo de Atributos
88,05 %	Estatísticos extraídos do Histograma
88,28%	Atributos de Forma e Estatísticos extraídos do Histograma
90,49%	Atributos de Forma, Estatísticos extraídos do Histograma e Momento de Hu
90,03%	Atributos de Forma, Estatísticos extraídos do Histograma, Atributos de textura de Haralick e Medida de Granulometria
91,07%	Atributos de Forma, Estatísticos extraídos do Histograma, Momento de Hu, Espectral no domínio de Radon e Medida de Granulometria
87,32%	Todos os Grupos de Atributos

FIGURA 9.13: Gráfico da taxa média de precisão da recuperação de imagens para um grupo de atributos. H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.

FIGURA 9.14: Gráfico da taxa média de precisão da recuperação de imagens para combinação de dois grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.

FIGURA 9.15: Gráfico da taxa média de precisão da recuperação de imagens para combinação de três grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.

FIGURA 9.16: Gráfico da taxa média de precisão da recuperação de imagens para combinação de quatro grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria

FIGURA 9.17: Gráfico da taxa média de precisão da recuperação de imagens para combinação de cinco grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.

FIGURA 9.18: Gráfico da taxa média de precisão da recuperação de imagens para combinação de todos os grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.

9.3.2 Avaliação pelo coeficiente de correlação

foi avaliado, também, o sistema de recuperação de imagens , calculando a taxa de precisão e revocação (precision e recall) de acordo com o coeficiente de correlação entre a imagem teste e as imagens recuperadas. Foi considerado como precisão, o coeficiente de correlação entre a imagem teste e as imagens recuperadas com valores acima do limiar. A revocação foi calculada entre as imagens obtidas da precisão e todas as imagens com coeficiente de correlação, acima do limiar em relação à imagem teste. Neste caso, os valores de revocação apresentaram-se bem baixos. Foram consideradas, neste caso, somente as imagens de mesma incidência e o limiar foi variado de 0.1 a 0.9. Foram utilizados os valores médios da precisão e revocação para a avaliação.

Para determinar os melhores resultados, foi traçado o gráfico do valor médio de precisão em função da revocação e calculada a área sob a curva. A figura 9.19, 9.20, 9.21, 9.22 e 9.23 mostram as curvas obtidas, respectivamente, para 1, 2, 3 , 4, 5 e todos os grupos de atributos. As tabelas 9.9, 9.10, 9.11, 9.12 e 9.13 apresentam os valores da área sob a curva dos resultados obtidos e os grupos de atributos correspondentes.

Analisando os resultados das tabelas 9.9 a 9.13, observa-se que o grupo de atributo de Textura de Haralick e Momento de Hu participam nas configurações em que o sistema teve o melhor desempenho, exceção na configuração com dois atributos. Os atributos espectrais no domínio de Radon e os de Medida de Granulometria participaram em duas configurações em que o sistema teve o melhor desempenho. Quando são utilizados todos os grupos de atributos o sistema tem desempenho menor do que com as outras configurações de atributos. Diferentemente da análise realizada com a classificação pela composição dos tecidos, os atributos de momentos estatísticos extraídos do histograma não participaram de nenhuma configuração de destaque na análise realizada. Comprovando a nossa hipótese de que ao ser levada em consideração a localização dos tecidos, os atributos que possuem essa característica dominam a medida de similaridade do sistema.

FIGURA 9.19: Gráfico do valor médio de precisão em função da revocação para 1 grupo de atributos. H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.

TABELA 9.9: Área sob a curva de precisão em função da revocação para um grupo de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.

Grupo de atributos	H	T	M	R	G
Área embaixo da curva	0,00677	0,02215	0,00271	0,01080	0,01064

FIGURA 9.20: Gráfico do valor médio de precisão em função da revocação para 2 grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.

TABELA 9.10: Área sob a curva de precisão em função da revocação para 2 grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.

Grupo de atributos	F, H	F, T	F, M	F, R	F, G
Área embaixo da curva	0,01140	0,021718	0,01386	0,01768	0,01382

FIGURA 9.21: Gráfico do valor médio de precisão em função da revocação para 3 grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.

TABELA 9.11: Área sob a curva de precisão em função da revocação para 3 grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.

Grupo de atributos	F,H,T	F,H,M	F,H,R	F,H,G	F,T,M
	F,T,R	F,T,G	F,M,R	F,M,G	F,R,G
Área embaixo da curva	0,01518	0,01613	0,01361	0,01301	0,02351
	0,01659	0,01825	0,00980	0,01189	0,01719

FIGURA 9.22: Gráfico do valor médio de precisão em função da revocação para 4 grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.

TABELA 9.12: Área sob a curva de precisão em função da revocação para 4 grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria

Grupo de atributos	F,H,T,M	F,H,T,R	F,H,T,G	F,H,M,R	F,H,M,G
	F,H,R,G	F,T,M,R	F,T,M,G	F,T,R,G	F,M,R,G
Área embaixo da curva	0,01794	0,01554	0,01695	0,01551	0,01032
	0,01066	0,01891	0,02329	0,01897	0,01509

FIGURA 9.23: Gráfico do valor médio de precisão em função da revocação para 5 e 6 grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria.

TABELA 9.13: Área sob a curva de precisão em função da revocação para 5 e 6 grupos de atributos. F: atributos de forma; H: momentos estatísticos extraídos do histograma; T: textura de Haralick; M: Momento de Hu; R: espectrais no domínio de Radon; G: medida de Granulometria

Grupo de atributos	F,H,T,M,R	F,H,T,M,G	F,H,M,R,G	F,H,T,R,G	F,T,M,R,G
	F,H,T,M,R,G				
Área embaixo da curva	0,01520	0,01839	0,01535	0,01846	0,01879
	0,01676				

Capítulo 10

Conclusões Finais

A equação de Difusão Anisotrópica com filtro de Wiener mostrou-se eficaz na diminuição e suavização do ruído, preservando a borda da mama na maioria das imagens. É uma contribuição relevante para o pré-processamento de imagens mamográficas com alta taxa de ruído.

O método de limiarização, apesar de sensível à presença de ruído, apresentou bons resultados tanto na segmentação da região da mama, como na segmentação da região de tecidos fibro-glandulares. A comparação entre as técnicas de limiarização foi uma contribuição importante para o processo de segmentação de imagens mamográficas. Destaque para o método da Matriz de Co-ocorrência que apresentou os melhores resultados de segmentação.

A transformada de Radon mostrou eficácia tanto na detecção de linha na imagem mamográfica, como na detecção da direção de densidade de tecidos mamários. A contribuição mais significativa foi da utilização da transformada de Radon para extração de atributos direcionais no domínio de Radon. A utilização da transformada de Radon como detector de direção de densidade é inédita.

Outra contribuição importante foi da utilização de atributos de medida de Granulometria como medida de textura da imagem mamográfica. O único problema da utilização dos atributos de medida de Granulometria é o tempo de processamento para a extração desses atributos. Esse alto custo

computacional foi devido ao filtro TopHat utilizado para realçar os tecidos figro-glandulares da imagem. Mas isso, não tira a relevância da contribuição da investigação realizada com esse atributo.

As Avaliações mostraram que os tipos de imagens recuperadas dependem da referência de avaliação adotada. Para avaliação que leva em consideração a composição dos tecidos, os atributos de momento estatístico extraídos do histograma foram dominantes na avaliação de recuperação, porém na avaliação com a precisão e revocação pelo coeficiente de correlação, o domínio foi dos atributos de textura de Haralick.

Por isso, a validação do sistema proposto com a análise visual das similaridades relevantes por parte de radiologistas especialistas é necessária.

No geral, os atributos mostraram que podem ser úteis na recuperação de imagens mamográficas em sistema CBIR. Essa investigação, foi a maior contribuição do trabalho como medida de similaridade para recuperação de imagens mamográficas. O desempenho mínimo obtido da taxa de precisão foi de 81%.

A rede de Mapas Auto-Organizáveis de Kohonen (SOM) teve bom desempenho como sistema recuperador de imagens mamográficas, demonstrado também em Laaksonen et al. (2000,2001). Porém, o sistema não possui estrutura para indexação das imagens.

A área sob a curva de precisão e revocação forneceu uma forma interessante de avaliação do desempenho médio dos sistemas de recuperação de imagens utilizados.

10.1 Propostas para trabalhos futuros

1. Investigar novos métodos de retirada de ruído baseados na transformada Wavelet.
2. Investigar métodos de segmentação de análise de vizinhança como o método de modelo de contorno ativo proposto por Ferrari (2002).
3. Aperfeiçoar o método de detecção da região do músculo peitoral para os casos em que o contorno da região muscular é irregular, apresenta baixo contraste entre o tecido muscular do peitoral com o tecido mamário próximo a essa região, e na presença de tecido muscular no prolongamento inferior da base da mama, próximo à parede torácica. Neste caso, pode-se utilizar a detecção da região do músculo peitoral com a imagem em nível de cinza sem a necessidade do detector de borda ou combinar a técnica proposta com outras que auxiliem na solução destes problemas.
4. Aperfeiçoar o método de detecção do mamilo com outras técnicas que ajustem a direção mais próxima do mamilo. Por exemplo, através de análise de gradiente da região próxima da borda da mama.
5. Realizar a validação do sistema proposto com a análise visual das similaridades relevantes encontradas nas imagens recuperadas por parte de especialistas e a implementação de um sistema de realimentação de relevância.
6. Implementar os atributos investigados em outros sistemas CBIR como o proposto por Vicentini (2002), onde há a combinação de uma rede neural da família ART com o sistema de indexação proposto por Traina Jr. et al. (2000).

10.2 Publicações relacionadas a esta tese

KINOSHITA, SK; AZEVEDO-MARQUES, PM; A method for edge restoration and breast region segmentation in noisy mammograms. **Computer Assisted Radiology and Surgery – CARS**, Chicago, EUA, june 2004.

(KINOSHITA, SK; PEREIRA JR, RR; HONDA, MO; RODRIGUES, JAH; AZEVEDO-MARQUES, PM; Segmentation of the breast region from noisy mammograms and automatically locating the nipple and pectoral muscle region. **International Workshop on Digital Mammography – IWDM**, San José, EUA, june 2004.

(KINOSHITA, SK; PEREIRA JR, RR; HONDA, MO; RODRIGUES, JAH; AZEVEDO-MARQUES, PM; An automatic method for detection of the nipple and pectoral muscle in digitized mammograms. **Congresso Latino Americano de Engenharia Biomédica – CLAEB**, João Pessoa, Pb, Brasil, setembro 2004.

(KINOSHITA, SK; PEREIRA JR, RR; HONDA, MO; RODRIGUES, JAH; AZEVEDO-MARQUES, PM; Recuperação Baseada em Conteúdo de Imagens Mamográficas: Atributos Visuais de Forma, Espectrais no domínio de Radon e Granulometria. **Congresso Brasileiro de Informática em Saúde– CBIS**, Ribeirão Preto, SP, Brasil, novembro 2004 (aceito).

Referências Bibliográficas

(ACR, 2004): AMERICAN CANCER SOCIETY, **Cancer Facts and Figures**, New York, 2004.

(AZEVEDO-MARQUES et al., 2002): AZEVEDO-MARQUES , PM; HONDA, MH; RODRIGUES, JAH; SANTOS, RR; TRAINA , AJM; TRAINA JR, C; BUENO, JM; Recuperação de imagem baseada em conteúdo: uso de atributos de textura para caracterização de microcalcificações mamográficas. **Radilogia Brasileira**, v.35(2), 2002, pp.93-98.

(BEALE & JACKSON, 1990): BEALE, R; JACKSON, T; **Neural computing: an introduction**. Adam-Hilger, Inst. of Physics Pub. Ltd., Bristol, 1990, 240p.

(BICK et al., 1995): BICK, U; GIGER, ML; SCHMIDT, RA; NISHIKAWA, RM; WOLVERTON, DE; DOI, K; Automated segmentation of digitized mammograms. **Academic Radiology**, v.2, 1995, pp.1-9.

(BISHOP, 1995): BISHOP, CM; **Neural networks for pattern recognition**. Claredon Press. Oxford, UK, 1995, 475p.

(BYNG et al., 1996): BYNG, JW; BOYD, NF; FISHELL, E; JONG, RA; YAFFE, MJ; Automated analysis of mammographic densities. **Phys. Med. Biol.**, v.41, 1996, pp.909-923.

(CADWELL et al., 1990): CADWELL, CB; STAPLETON, SJ; HOLDSWORTH, DW; JONG, RA; WEISER, WJ; COOKE, G; YAFFE, MJ; Characterization of mammographic parenchymal pattern by fractal dimension. **Phys Med. Biol.**, v.35, 1990, pp.235-247.

(CANNY, 1986): CANNY, J: A computational approach to edge detection. **IEEE Transactions Pattern Analysis and Machine Intelligence**, PAMI-8 (6), 1986, pp.679-698.

(CATTÉ et al., 1992a): CATTÉ F; LIONS, PL; MOREL, JM; COLL, T; Image selective smoothing and edge detection by nonlinear diffusion-I, **SIAM, J. Numer. Anal.**, v.29(1), 1992, pp.182-193.

(CATTÉ et al., 1992b): CATTÉ F; LIONS, PL; MOREL, JM; COLL, T; Image selective smoothing and edge detection by nonlinear diffusion-II, **SIAM, J. Numer. Anal.**, v.29(1), 1992, pp.845-866.

(CHANDRASEKHAR & ATTIKIOUZEL, 1997): CHANDRASEKHAR, R & ATTIKIOUZEL, Y; A simple method for automatically locating the nipple on mammograms. **IEEE Transactions on Medical Imaging**, v.6(5), 1997, pp.483-494.

(DEANS, 1981): DEANS, SR; Hough transform from the Radon transform. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v.3, 1981, pp.185-188.

(DOI, 1999): DOI, K.; Computer-aided diagnosis and its potential impact on diagnostic radiology. *In*: Doi K, MacMahon H, Giger ML, Hoffmann KR, eds. **Computer-aided diagnosis in medical imaging**. Amsterdam: Elsevier Science, 1999, pp.11-20.

(DOUGHERTY et al., 1992): DOUBHERTY, ER; NEWELL, JT; PELZ, JB; Morphological texture-maximum-likelihood pixel classification based on local granulometric moments. **Pattern Recognition**, v.25(10), 1992, pp.1181-1198.

(DOYLE, 1962): DOYLE, W; Operations useful for similarity-invariant pattern recognition. **J. Assoc. Comput. Math.**, v.9, 1962, pp.259-267.

(EL-FARAMAWY et al., 1996): EL-FARAMAWY, NM; RANGAYYAN, RM; DESAUTELS, JEL; ALIM, OA; Shape factors for analysis of breast tumors in mammograms. **IEEE Proc. Canadian Conf. on Electrical and Computer Eng.**, 1996, pp.355-358.

(EL-NAQA et al., 2002a): EL-NAQA, I; YANG, Y; GALATSANOS, NP; WERNICK, MN; Content-based image retrieval for digital mammography. **IEEE International Conference on Image Processing**, Rochester, NY, 2002.

(EL-NAQA et al., 2002b): EL-NAQA, I; YANG, Y; GALATSANOS, NP; WERNICK, MN; NISHIKAWA, R; Support vector machine learning for detection of microcalcification in mammograms. **IEEE International Symposium on Biomedical Imaging**, Washington D.C., 2002.

(FAUSETT, 1994): FAUSET, L; **Fundamentals of neural networks - architectures, algorithms, and applications**, Prentice Hall Int., Inc., New Jersey, 1994, 461p.

(FERRARI et al., 2000): FERRARI, RJ; RANGAYYAN, R; DESAUTELS, JEL; FRÈRE, A.; Segmentação de mamogramas: identificação da borda da mama, músculo peitoral e disco glandular. **Anais do CBEB'2000**, 2000, pp.1255-1261.

(FERRARI, 2002): FERRARI, RJ; **Deteção computacional de assimetrias entre mamogramas.**, 2002, 165p, tese – Escola de Engenharia de São Carlos – USP, São Carlos-SP, Brasil

(FERRARI et al., 2004): FERRARI, RJ; RANGAYYAN, R; DESAUTELS, JEL; BORGES, RA; FRÈRE, A.; Automatic identification of the pectoral muscle in mammograms. **IEEE Transactions on Medical Imaging**, v.23(2), 2004, pp.232-245.

(GIGER, 1999): GIGER, M.L.; Computer-aided diagnosis. **RSNA Categorical Course in Breast Imaging**, 1999, pp.249-72.

(GONZALEZ & WOODS, 2000): GONZALEZ, RC; WOODS, RE; **Processamento de imagens digitais**. Tradução Roberto M. Cesar Junior e Luciano da Fontoura Costa. São Paulo: Editora Edgard Blücher Ltda, 2000, 509p. Título original: Digital Image Processing.

(GONZALEZ & WOODS, 2001): GONZALEZ, RC; WOODS, RE; **Digital Image Processing, 2nd ed.** Prentice Hall, New Jersey/USA, 2001.

(GUDIVADA & RAGHAVAN, 1995): GUDIVADA, VN; RAGHAVAN, VV; Content-based image retrieval system. **IEEE computer**, v.28(9), 1995, pp.18-22.

(HARALICK et al., 1973): HARALICK, RM; SHANMUGAM, K; DINSTEN, I; Texture features for image classification. **IEEE Trans. Systems Man Cybernet**, SMC-3, 1973, pp.610-621.

(HARALICK, 1974): HARALICK, RM; A measure of circularity of digital figures. **IEEE Trans. System Man**, Cybernetics SMC-3, 1974, pp.394-396.

(HAYKIN, 1994): HAYKIN, S; **Neural networks - a comprehensive foundation**, Prentice Hall Inc., New Jersey, 1994, 696p.

(HAYTON, 1998): HAYTON, P; **Analysis of contrast enhanced breast MR images**, 1998, DPhil. dissertation, Engineering Science, Oxford Univ., Oxford, UK.

(HEINE et al., 1998): HEINE, JJ; KALERGI M, CHETELAT, SM; CLARKE LP; Multiresolution wavelet approach for separating the breast region from the background in high resolution digital mammography. In **Digital mammography '98 Dordrecht: Kuwer, N Kassemeijer** (ed), 1998, pp.295-298.

(HEINE & VELTHUIZEN, 2000): HEINE, JJ; VELTHUIZEN, RP; A statistical methodology for mammographic density detection. **Medical Physics**, v.27(12), 2000, pp.2644-2651.

(HONDA et al., 2002): HONDA, MO; RODRIGUES, JAH; PEREIRA JR, RR; AZEVEDO-MARQUES, PM; Uso de atributos de textura para minimização do "gap" semântico em sistema de recuperação de imagem baseada em conteúdo (CBIR). **Anais do VIII Congresso Brasileiro de Informática em Saúde (CBIS'2002)**, Natal/RN, 2002, em CD-ROM.

(HU, 1962): HU, MK; Visual pattern recognition by moment invariants. **IRE Trans. on Inf. Theory**, v.8(2), 1962, pp.170-187.

(HUO et al., 2000): HUO, A; GIGER, ML; WOLVERTON, DE; ZHONG, W; Computerized analysis on mammographic parenchymal patterns for breast cancer risk assessment: feature selection. **Medical Physics**, v.27(1), 2000, pp.4-12.

(JAIN, 1989): JAIN, AK; **Fundamentals of digital image processing**. Prentice Hall Int. 1989.

(KAPUR et al., 1985): KAPUR, JN; SAHOO, PK; WONG, AKC; A new method for grey-level picture thresholding using the entropy of the histogram. **Computer Vision, Graphics, and Image Processing**, v.29, 1985, pp.273-285.

- (KASSEMEIJER, 1998): KASSEMEIJER, N.; Automated classification of parenchymal patterns in mammograms. **Phys. Med. Biol.**, v.43, 1998, pp.365-378.
- (KINOSHITA et al., 1999): KINOSHITA, SK; AZEVEDO-MARQUES, PM; FRÈRE, AF; MARANA, HRC; FERRARI, RJ; VILLELA, RL; Characterization of breast masses using texture and shape features. In Doi K, MacMahon H, Giger ML, Hoffmann kr (eds), **Computer-aided diagnosis in medical imaging**. Amsterdam: Elsevier Science B.V., 1999, pp.265-270.
- (KINOSHITA et al., 1999): KINOSHITA, SK; AZEVEDO-MARQUES, PM; FRÈRE, AF; MARANA, HRC; FERRARI, RJ; VILLELA, RL; Comparative of shape and texture features in classification of breast masses in digitized mammograms. **Proceedings of SPIE's International Medical Imaging 2000**, San Diego, USA.
- (KOHONEN, 1990): KOHONEN, T; The self-organizing map. **Proceedings of IEEE**, v.78(9), 1990, pp.1464-1480.
- (LAAKSONEN et al., 2000): LAAKSONEN, J; KOSKELA, M; LAAKSO, S; OJA, E; PicSOM – content-based image retrieval with self-organizing maps. **Pattern Recognition Letters**, v.21(13-14), 2000, pp.1199-1207.
- (LAAKSONEN et al., 2001): LAAKSONEN, J; KOSKELA, M; LAAKSO, S; OJA, E; Self-Organizing maps as a relevance feedback technique in content-based image retrieval. **Pattern Analysis & Applications**, v.4(2-3), 2001, pp.140-152.
- (LAI et al., 1989): LAI, S.M.; LI, X.; BISCHOP, W.F.; On techniques for detection circumscribed masses in mammograms. **IEEE Transactions on Medical Imaging**, v.8(4), 1989, pp.377-386.
- (LIU et al., 1991): LIU, Z-Q; RANGAYYAN, RM; FRANK, CB; Directional analysis of images in scale space. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v.13(11), 1991, pp.1185-1192.
- (LLOYD, 1982): LLOYD, S; Least squares quantization in PCM. **IEEE Transactions Information Theory**, v.28, 1982, pp.129-137.
- (LOH et al., 2001): LOH, AWK; ROBEY, MC; WEST, GAW; Analysis of the interaction between edge and line finding techniques. **Pattern Recognition**, v.24, 2001, pp.1127-1146..
- (MÉNDEZ et al., 1996): MÉNDEZ, AJ; TAHOCES, PG; LADO, MJ; SOUTO, M; CORREA, JL; VIDAL, JJ; Automatic detection of breast border and nipple in digital mammograms. **Computer Methods and Programs in Biomedicine**, v.49, 1996, pp.253-262.
- (MOSCOWITZ et al., 1980): MOSCOWITZ, M; GARTSIDE, P; MCLAUGHLIN, C; Mammographic patterns as markers for high-risk benign breast disease and incident cancers. **Radiology**, v.134, 1980, pp.293-295.
- (MOSCOWITZ, 1983): MOSCOWITZ, M; Screening for breast cancer: how effective are our test? a critical review. **CA Cancer J. Clin.**, v.33, 1983, pp.25-39.

(NISHIKAWA et al, 2000): NISHIKAWA, RM; GIGER, ML; VYBORNÝ, CJ; BICK, U.; DOI, K.; SCHMIDT, RA; Prospective computer analysis of cancer missed on screening mammography. In **Proceeding of 5th International workshop on Digital Mammography**, MJ Yaffe (ed), Toronto, Canada, 2000, pp.493-498.

(OJALA et al., 2001): OJALA, T; NÄPPI, J; NEVALAINEN, O; Accurate segmentation of breast region from digitized mammograms. **Computerized Medical Imaging and Graphics**, v.25, 2001, pp. 47-59.

(OTSU, 1978): OTSU, N; A threshold selection method from gray-level histogram. **IEEE Trans. Systems Man Cybernet**, SMC-8, 1978, pp.62-66.

(PERONA & MALIK, 1990): PERONA, P; MALIK, J; Scale-space and edge detection using anisotropic diffusion. **IEEE Trans. on Pattern Analysis and Machine Intelligence**, v.12(7), 1990, pp.629-639.

(PETROSIAN et al., 1994): PETROSIAN, A; CHAN, HP; PETRICK, N; WEI, D; HELVIE, MA; ADLER, DD; GOODSITT, MM; Computer-aided diagnosis in mammography: classification of mass and normal tissue by texture analysis. **Phys. Med. Biol.**, v.39, 1994, pp.2273-2288.

(PIZURICA et al., 2003): PIZURICA, A; PHILIPS, W; LEMAHIEU, I; ACHEROV, M; VERSATILE, A; Wavelet domain noise filtration technique for medical imaging. **IEEE Transactions on Medical Imaging**, v.22, 2003, pp.?

(POHLMAN et al., 1996): POHLMAN, S; POWELL, KA; OBUCHOWSKI, NA; CHILCOTE, WA; BRONIATOWSKI, SG; Quantitative classification of breast tumors in digitized mammograms. **Medical Physics**, v.23(8), 1996, pp.1337-1345.

(POLLEI et al., 1987): POLLEI, SR; METTLER, FA JR; BARTOW, SA; MORADIAN, G; MOSKOWITZ, M; Occult breast cancer: prevalence and radiographic detectability. **Radiology**, v.163, 1987, pp.459-462.

(RANGAYYAN et al., 1994): RANGAYYAN, RM; EL-FARAMAWY, NM; DESAUTELS, JEL; ALIM, OA; Discrimination between benign and malignant breast tumors using a region-based measure of edge profile acutance. **Proceeding of the 3rd International Workshop on Digital Mamography**, 1996, pp.213-218.

(RANGAYYAN & ROLSTON, 1998): RANGAYYAN, RM; ROLSTON, WA; Directional image analysis with the Hough and Radon transforms. **J. Indian Inst. Sci.**, v.78, 1998, pp.3-16.

(REDDI et al., 1984): REDDI, SS; RUDIN, SF; KESHAVAN, HR; An optimal multiple threshold scheme for image segmentation. **IEEE Trans. on System, Man, and Cybern.**, SMC-14, 1984, pp.661-665.

(RIDLER & CALVARD, 1978): RIDLER, T; CALVARD, S; Picture thresholding using an iterative selection method. **IEEE Trans. on System, Man, and Cybern.**, SMC-8, 1978, pp.630-632.

(ROSIN, 2001): ROSIN, PL; Unimodal thresholding, **Pattern Recognition**, v.34, 2001, pp.2083-2096.

- (RUI et al., 1997): (RUI, Y; HUANG, TS; CHANG, S-F; Image retrieval: past, present and future. In **Proc. Int. Symp. Multimedia Inform. Processing**, Taiwan, 1997.
- (SAHA et al., 2001): SAHA, PK; UDUPPA, JK; CONANT, EF; CHAKRABORTY, DP; SULLIVAN, D; Breast tissue density quantification via digitized mammograms. **IEEE Transactions on Medical Imaging**, v.20(8), 2001, pp.792-803.
- (SAHOO et al., 1988): SAHOO, PK; SOLTANI, S; WONG, AKC; CHEN, YC; A survey of thresholding techniques. **Computer Vision, Graphics, and Image Processing**, v.41, 1988, pp.233-260.
- (SALLAM & BOWYER, 1999): SALLAM, MY & BOWYER, KW; Registration and difference analysis of corresponding mammogram images. **Medical Image Analysis**, v.3(2), 1999, pp.103-118.
- (SANTOS ANDRÉ et al., 2004): SANTOS ANDRÉ, TCS; AZEVEDO-MARQUES, PM; RODRIGUES, JAH; RANGAYYAN, RM; Content-based image retrieval using self-organizing maps and cross-correlation. **III Congresso Latino-Americano de Engenharia Biomédica (CLAEB'2004)**, João Pessoa/PB, 2004.
- (SCHMIDT et al., 1998): SCHMIDT, RA; NEWSTEAD, GM; LINVER, MN; EKLUND, GW; METZ, CE; WINKLER, MA; NISHIKAWA, RM; Mammographic screening: sensitivity of general radiologist. In **Proceedings of the 4th International Workshop on Digital Mammography**, Kassemeyer, N; Thijssen, M; Hendricks, J; van Erning, L (eds), Nijmegen, The Netherlands, 1998, pp.383-388.
- (SEGALL & ACTON, 1997): SEGALL, CA; ACTON, ST; Morphological anisotropic diffusion. **IEEE International Conference on Image Processing**, Santa Barbara, California, USA, 1997, pp.348-351.
- (SEMMLOW et al., 1980): SEMMLOW, JL; SHADAGOPAPPAN, A; ACKERMAN, LV; HAND, W; ALCORN, FS; A fully automated system for screening xeromammograms. **Comput. Biomed. Res.**, v.13, 1980, pp.350-362.
- (SERRA, 1998): SERRA, J; **Image Analysis and Mathematical Morphology: Theoretical advances**. Academic Press, London, 2000.
- (SERSIC & LONCARIC, 1998): SERSIC, D; LONCARIC, S; **Enhancement of mammographic images for detection of microcalcifications**. Zagreb, Croatia: 1998, (Technical report – Department of Electronic Systems and Information Processing, pp.1-4).
- (SIVARAMAKRISNA et al., 2001): SIVARAMAKRISNA, R; OBUKHOWSI, NA; CHILCOTE, WA; POWELL, KA; Automatic segmentation of mammographic density. **Academic Radiology**, v.8(3), 2001, pp.250-256.
- (SMEULDERS et al., 2000): SMEULDERS, AWM; WORRING, M; SANTINI, S; GUPTA, A; JAIN, R; Content-based image retrieval at the end of the early years, **IEEE Transactions Pattern Analysis and Machine Intelligence**, v. 22(12), 2000, pp. 1349-1380.

(SONKA & PATRICK, 2000): SONKA, M; PATRICK, F; **Hanbook of Medical Imaging: Medical Imaging Processing and Analysis, vol 2.** SPIE Press. Washington/USA, 2000.

(SWANSON, 1992): SWANSON,GM; Breast cancer in the 1990's. **J. Am. Med. Women Assoc.**, v.47, 1992, pp.140-148.

(TSAI, 1985): TSAI, W; Moment-preserving thresholding: a new approach. **Computer Vision, Graphics, and Image Processing**, v.29, 1985, pp.377-393.

(TAHOCES et al., 1995): TAHOCES, PG; CORREA, J; SOUTO, M; GÓMEZ, L; VIDAL, JJ; Computer-assisted diagnosis: the classification of mammographic breast parenchymal patterns. **Phys Med Biol**, c.40, 1995, pp.103-117.

(te BRAKE et al., 2000): te BRAKE, GM; KASSEMEIJER, N; HENDRICKS, HCL; An automatic method to discriminate malignant masses from normal tissue in digital mammograms. **Phys. Med. Biol.**, v.45, 2000, pp.2843-2857.

(TH'EVENTAZ et al., 2000): TH'EVENTAZ, P; BLU, T; UNSER, M; Interpolation revisited. **IEEE Trans. on medical imaging**, v. 19 (7), 2000, pp.739-758.

(TRAINA JR. Et al., 2000): TRAINA JR., CJM; TRAINA, A; FALOUTSOS, C; Slim-trees: High performance metric trees minimizing overlap between nodes. In **Advances in Database Technology**, Springer, v. 1777, pp.51-65.

(VICENTINI, 2002): VICENTINI, JF; **Indexação e recuperação de informações utilizando redes neurais da família ART**, 2002, 95p - Dissertação, ICMS - Instituto de Ciências Matemáticas e de Computação - USP, São Carlos - SP, Brasil.

(ZHOU et al., 2001): ZHOU, C; CHAN, H-P; PETRICK, N; HELVIE, MA; GOODSITT, MM; SAHINER, B; HADJJISKI, LM; Computerized image analysis: estimation of breast density on mammograms. **Medical Physics**, v.28(6), 2001, pp.1056-1069.

(WIRTH & STAPINSKI, 2003): WIRTH, MA ; STAPINSKI, A; Segmentation of the breast region using active contours. In **Visual Communications and Image Processing**, T. Ebrahimi and T. Sikora (eds), Lugano, Switzerland, 2003, v.5150, pp.1995-2006.

(WOLFE, 1967): WOLFE, JN; Mammography: ducts as a sole indicator of breast carcinoma. **Radiology**, v.89, 1967, pp.206-210.

(WOLFE, 1976a): WOLFE, JN; Breast pattern as an index of risk for developing breast cancer. **American J. Roentgenol**, v.126, 1976, pp.1130-1139.

(WOLFE, 1976b): WOLFE, JN; Breast parenchymal patterns and their changes with ages. **Radiology**, v.121, 1976, pp.545-552.

(WOLFE, 1976b): WOLFE, JN; Risk for breast cancer development determined by mammographic parenchymal pattern. **Cancer**, v.37, 1976, pp.2486-2492.

(YAM et al., 2001): YAM, M; BRADY, M; HIGHNAM, R; BEHRENBRUCH, C; ENGLISH, R; KITA, Y; Three-dimensional reconstruction of microcalcification clusters from two mammographic views. **IEEE Transactions on Medical Imaging**, v.20(8), 2001, pp.479-489.

(YIN et al., 1994): YIN, F-F; GIGER, ML; DOI, K; VYBORNÝ, CJ; SCHMIDT, RA; Computerized detection of masses in digital mammograms: automated alignment of breast images and its effect on bilateral-subtraction techniques. **Medical Physics**, v.21(3), 1994, pp.445-451.