

**CLASSIFICAÇÃO DE LESÕES DE MAMA CONTENDO  
MICROCALCIFICAÇÕES ASSOCIADAS**

**Ricardo José Ferrari**

Dissertação apresentada à Escola de Engenharia de São Carlos, Universidade de São Paulo, como parte dos requisitos para obtenção do Título de Mestre em Engenharia Elétrica.

**Orientador: Prof. Dr. Paulo Mazzoncini de Azevedo Marques**

DEDALUS - Acervo - EESC



31100016500




**São Carlos**

**1998**

## FOLHA DE APROVAÇÃO

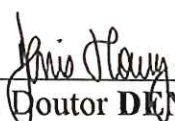
Candidato: Engenheiro **RICARDO JOSÉ FERRARI**

Dissertação defendida e aprovada em 29.09.98  
pela Comissão Julgadora:

  
\_\_\_\_\_  
Prof. Dr. **PAULO MAZZONCINI DE AZEVEDO MARQUES (Orientador)**  
(Escola de Engenharia de São Carlos - Universidade de São Paulo)

  
\_\_\_\_\_  
Prof. Dr. **NELSON DELFINO D'ÁVILA MASCARENHAS**  
(Universidade Federal de São Carlos - UFSCar)

  
\_\_\_\_\_  
Prof. Tit. **ANNIE FRANCE FRÈRE SLAETS**  
(Escola de Engenharia de São Carlos - Universidade de São Paulo)

  
\_\_\_\_\_  
Prof. Doutor **DENIS VINICIUS COURY**  
Coordenador da Área de Engenharia Elétrica

  
\_\_\_\_\_  
**JOSÉ CARLOS A. CINTRA**  
Presidente da Comissão de Pós-Graduação da EESC

Aos meus pais, pela compreensão,  
esforços e apoio dados em todas as  
etapas de minha vida.

A minha esposa Luciana, por seu amor,  
atenção e crença em meu trabalho.

## AGRADECIMENTOS

- Ao professor e amigo Paulo Mazzoncini de Azevedo Marques, meu orientador, pela orientação, apoio e cooperação para a realização desse trabalho.
- Em especial à professora Annie France Frère Slaets, pela colaboração tão valiosa, amizade e confiança em meu trabalho.
- Ao professor Nelson D.A. Mascarenhas, pela sua atenção e enorme paciência fornecidas no esclarecimento de minhas dúvidas sobre Estatística e Reconhecimento de Padrões.
- Ao amigo Sérgio Kinoshita pelas valiosas discussões sobre processamento de imagens e redes neurais.
- Aos amigos do laboratório: Henrique, Irita,, Chico Bento, Silvia, Renata, Márcia, Marcelo, Leonardo, Márcio e Lucas, pelo convívência diária tão agradável.
- Aos médicos Heitor R.C.Marana e Luciano A.R. Spina do Departamento de Ginecologia e Obstetrícia da Faculdade de Medicina de Ribeirão Preto pela enorme colaboração neste trabalho.
- Às competentes secretárias do Departamento de Engenharia Elétrica, Rosane Aranda e Patrícia pela ajuda, paciência e amizade.
- A Doris Barnes, minha professora de Inglês, pelas infindáveis discussões na confecção de artigos e do abstract.
- A Fundação de Amparo à Pesquisa de São Paulo - FAPESP - pelo apoio financeiro.

## RESUMO

Neste trabalho é proposto um sistema computacional para auxílio ao diagnóstico de câncer de mama com microcalcificações associadas. O sistema é composto por 3 etapas principais: segmentação, extração de atributos e classificação.

Na etapa de segmentação, a região suspeita do mamograma digitalizado (ROI - região de interesse) é processada para isolar as microcalcificações das estruturas normais da imagem. O resultado final é uma imagem binária contendo apenas as microcalcificações. Nesta etapa são utilizadas três técnicas combinadas: linearização do histograma da imagem ("stretching"), imagem-diferença e "thresholding" adaptativo.

Na etapa de extração de atributos, são realizadas 34 medidas: 13 medidas de textura, calculadas da ROI da imagem não segmentada, 19 medidas de forma das microcalcificações, 1 medida de distribuição e 1 de quantidade das microcalcificações, calculadas da ROI da imagem segmentada. A partir dos métodos erro de Bayes e distância JM, são separados os 6 melhores atributos para compor o vetor de atributos utilizado na classificação.

Na etapa de classificação, são avaliados três diferentes classificadores: Regra de Bayes (método paramétrico), k-NN (método não-paramétrico) e Rede Neural Artificial – tipo MLP (Perceptron multi-camadas). Os classificadores são treinados e testados com diferentes grupos de amostras, utilizando a técnica "leave-k-out".

Por fim, os resultados obtidos em cada etapa são apresentados e discutidos a partir de tabelas e curvas ROC.

## ABSTRACT

In the present work, a computerized system has been proposed to aid in the diagnosis of breast cancer with associated microcalcifications. The system is composed of 3 main stages: segmentation, features extraction, and classification.

In the segmentation stage, the suspected region in the digitized mammogram is processed to isolate the microcalcifications from the normal structures of the image. The final result is a binary image which has only microcalcifications. At this stage three combined techniques have been used: the stretching method, the image-difference and a thresholding adaptive method.

At the feature extraction stage, 34 measurements were implemented: 13 of texture, calculated from the ROI of the original image, 19 of shape, 1 of distribution and 1 measure related of the number of the microcalcification. To compose the feature space, a subset of the six best features were evaluated using the Bayes error and Jeffreys-Matusita methods.

In the classification stage, three classifiers were evaluated: the Bayes rules (parametric method), the k-Nearest Neighbour (non-parametric method), and a MLP (Multi-layer perceptron) Artificial Neural Network. The classifiers were trained and tested with different sample groups using the leave-k-out method.

The final results obtained at each stage are shown and discussed using the receiver operating characteristic (ROC) curves and tables.

# Sumário

<b>LISTA DE FIGURAS</b> .....	<b>IV</b>
<b>ÍNDICE DE TABELAS</b> .....	<b>VI</b>
<b>CAPÍTULO 1</b> .....	<b>1</b>
INTRODUÇÃO .....	1
1.1 - A IMPORTÂNCIA DA MAMOGRAFIA .....	2
1.2 - PRINCIPAIS INDICADORES DE LESÕES DE MAMA .....	2
1.3 - OBJETIVOS DA PESQUISA .....	6
1.4 - CONTRIBUIÇÕES DO TRABALHO.....	7
1.5 – ORGANIZAÇÃO DESTA DISSERTAÇÃO .....	7
<b>CAPÍTULO 2</b> .....	<b>9</b>
ESTADO DA ARTE NA DETECÇÃO E CLASSIFICAÇÃO DE MICROCALCIFICAÇÕES EM IMAGENS MAMOGRÁFICAS.....	9
2.1 - DETECÇÃO E SEGMENTAÇÃO DE MICROCALCIFICAÇÕES.....	11
2.2 - CLASSIFICAÇÃO DE MICROCALCIFICAÇÕES ISOLADAS .....	20
2.2.1 – <i>Classificação através da comparação entre atributos</i> .....	20
2.2.2 - <i>Classificação utilizando transformada de Hough</i> .....	22
2.2.3 – <i>Classificação através de Métodos Estatísticos</i> .....	23
2.2.4 – <i>Classificação através de Redes Neurais Artificiais</i> .....	30
2.3 - CLASSIFICAÇÃO DE AGRUPAMENTOS DE MICROCALCIFICAÇÕES .....	32
2.3.1 – <i>Classificação através de Redes Neurais Artificiais</i> .....	32
2.3.2 - <i>Classificação de lesões de mama através de informações fornecidas por especialistas</i> ..	37
<b>CAPÍTULO 3</b> .....	<b>39</b>
PRINCIPAIS ATRIBUTOS UTILIZADOS NA CLASSIFICAÇÃO DE LESÕES DE MAMA .....	39
3.1 - ATRIBUTOS EXTRAÍDOS DE MICROCALCIFICAÇÕES ISOLADAS.....	39
3.1.1 - <i>Momentos regulares</i> .....	40
3.1.2 - <i>Momentos de borda de região</i> .....	41
3.1.3 – <i>Fator de forma a partir de Descritores de Fourier</i> .....	44
3.1.4 - <i>Grau de compactação ( Solidez )</i> .....	45
3.1.5 – <i>Medidas de forma e suavidade</i> .....	46
3.1.6 – <i>Medidas de densidade intrapartícula</i> .....	47
3.1.7 – <i>Outras medidas de distribuição e número das microcalcificações</i> .....	48
3.1.8 – <i>Medida de Excentricidade</i> .....	48
3.2 – ATRIBUTOS DE TEXTURA EXTRAÍDOS DE REGIÕES DE INTERESSE DOS MAMOGRAMAS .....	49

3.2.1 - Estatísticas do Histograma de Segunda Ordem.....	49
3.2.1.1 - Entropia.....	50
3.2.1.2 - Contraste de $p(i,j)$ .....	50
3.2.1.3 - Segundo Momento Angular (SMA) de $p(i,j)$ .....	50
3.2.1.4 - Momento da diferença inversa .....	51
3.2.1.5 - Correlação de $p(i,j)$ .....	51
3.2.1.6 - Média, Variância e Entropia de $p_{x+y}$ .....	51
3.2.1.7 - Média, Variância e Entropia de $p_{x-y}$ .....	52
3.2.1.8 - Medidas de informação de correlação 1 e 2 (Mic_1 e Mic_2).....	52
<b>CAPÍTULO 4 .....</b>	<b>54</b>
TÉCNICAS UTILIZADAS PARA A SELEÇÃO E CLASSIFICAÇÃO DE ATRIBUTOS.....	54
4.1 - TÉCNICAS PARA A SELEÇÃO DE ATRIBUTOS.....	54
4.2 - TÉCNICAS ESTATÍSTICAS UTILIZADAS NA CLASSIFICAÇÃO DE LESÕES DE MAMA.....	55
4.2.1 - Teoria de decisão de Bayes .....	56
4.2.1.1 - Regra de Bayes para o mínimo erro (sem rejeição) .....	57
4.2.1.2 - Regra de Bayes para o mínimo erro (com rejeição).....	58
4.2.1.3 - Regra de Bayes para mínimo risco (sem rejeição).....	59
4.2.1.4 - Regra de Bayes para mínimo risco (com rejeição) .....	62
4.2.1.5 - Treinamento e Aprendizado .....	62
4.2.2 - Método K-NN (K-vizinho mais próximo).....	64
4.2.3 - Redes Neurais.....	65
<b>CAPÍTULO 5 .....</b>	<b>67</b>
CONCLUSÕES DO ESTUDO REALIZADO.....	67
5.1 - CONSIDERAÇÕES SOBRE OS ATRIBUTOS UTILIZADOS NA CLASSIFICAÇÃO .....	68
5.2 - CONSIDERAÇÕES SOBRE AS TÉCNICAS DE CLASSIFICAÇÃO.....	69
<b>CAPÍTULO 6 .....</b>	<b>70</b>
MATERIAIS E MÉTODOS .....	70
6.1 - BASE DE DADOS UTILIZADA .....	70
6.2 - MICROCOMPUTADOR E SOFTWARES UTILIZADOS .....	72
6.3 - SOFTWARE DESENVOLVIDO .....	73
6.3.1 - Programa de Gerenciamento da base de dados.....	75
6.3.2 - Método de Segmentação desenvolvido.....	75
6.3.2.1 - Método “Stretching” .....	75
6.3.2.2 - Imagem-diferença.....	76
6.3.2.3 - “Thresholding” local adaptativo.....	78
6.3.3 - Algoritmos dos principais atributos implementados .....	79
6.3.4 - Métodos utilizados para a seleção de atributos .....	85
6.3.4.1 - Erro de Bayes .....	85
6.3.4.2 - Distância “Jeffries-Matusita” .....	87



6.3.5 – Métodos de Classificação implementados .....	89
6.3.5.1 - Classificadores Bayesianos .....	89
6.3.5.2 - Método K-NN .....	91
6.3.5.3 - Redes Neurais Artificiais.....	92
6.4 – METODOLOGIA UTILIZADA NA ANÁLISE DE RESULTADOS .....	96
6.4.1 - Teoria da detecção de sinal .....	96
6.4.2 - Matriz de estímulo-resposta.....	97
6.4.3 - Curva característica de operação do receptor (curva ROC).....	98
6.4.4 - A geração de curvas ROC na prática .....	99
6.4.5 - Comparação de curvas ROC.....	100
6.4.6 - Área sob a curva ROC .....	100
<b>CAPÍTULO 7 .....</b>	<b>102</b>
DESCRICHÃO E ANÁLISE DOS RESULTADOS OBTIDOS .....	102
7.1 – SOFTWARE DE GERENCIAMENTO DA BASE DE DADOS .....	102
7.2 – SEGMENTAÇÃO .....	105
7.3 – SELEÇÃO DE ATRIBUTOS .....	109
7.4 – CLASSIFICAÇÃO .....	114
7.4.1 – Regra de Bayes.....	114
7.4.2 – Método k-NN .....	129
7.4.3 – Perceptron Multicamadas .....	132
<b>CAPÍTULO 8 .....</b>	<b>136</b>
CONCLUSÕES FINAIS.....	136
SUGESTÕES PARA FUTUROS TRABALHOS.....	138
<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>140</b>

# Lista de Figuras

## CAPÍTULO 1

- Figura 1.1 - Alguns exemplos dos principais sinais utilizados por radiologistas. a, b - agrupamentos de microcalcificações, c, d - nódulos com contornos bem definidos, e, f - nódulos com contornos irregulares.....4

## CAPÍTULO 2

- Figura 2.1 - Curvas ROC para detecção de agrupamentos de microcalcificações [WOODS-94].....18

## CAPÍTULO 4

- Figura 4.1 - Etapas da Classificação - [DICKHAUS-96].....54

## CAPÍTULO 6

- Figura 6.1 - Diagrama de blocos geral do sistema. ....74
- Figura 6.2 - Núcleos e perfis dos filtros usados pela técnica imagem-diferença - [CHAN-88A]. ....78
- Figura 6.3 - Definição das orientações  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$  do pixel central, para o cálculo da matriz de co-ocorrência de níveis de cinza - [HARALICK-73]. ....80
- Figura 6.4 - Erro de Bayes para um problema de decisão envolvendo um atributo e duas classes - [FUKUNAGA-90].....86
- Figura 6.5 - Informações de uma matriz de estímulo-resposta, expressas em forma gráfica usando  $p(S | s)$  e  $p(S | n)$  como coordenadas dos pontos A e B. ....99
- Figura 6.6 - Exemplos de curvas ROC quando a relação sinal ruído é aumentada. ....101
- Figura 6.7 - Exemplo de curvas ROC interceptadas. ....101

## CAPÍTULO 7

- Figura 7.1 - Tela de identificação da paciente: contém informações que facilitam a localização de outras informações clínicas dentro do arquivo do Hospital. ....102

Figura 7.2 - Tela de antecedentes: contém informações dos antecedentes familiares, menstruais, pessoais e obstétricos. ....	103
Figura 7.3 - Tela da história da moléstia atual e alterações em exames: contém informações dos problemas atuais e laudos de alterações mamográficas e ecográficas. ....	103
Figura 7.4 - Tela contendo informações diversas e o laudo geral da paciente. ....	104
Figura 7.5 - (a)-(d) Imagens antes ( ( a) e (c) ) e depois ( ( b) e (d) ) da aplicação do método "stretching". Todas as imagens possuem aumento de 6 vezes em relação ao tamanho original. Os valores de níveis de cinza mínimo e máximo para a imagem (a) são 28 e 85, e para a imagem (b) são 0 e 255. ....	105
Figura 7.6 - Estágios do método de segmentação (a) Imagem original da ROI (b) Imagem após a aplicação da técnica imagem-diferença. ....	106
Figura 7.7 - Estágios do método de segmentação (a) Imagem original da ROI (b) Imagem após a técnica de "stretching" (c) Imagem após a aplicação da técnica imagem-diferença. ....	106
Figura 7.8 - Thresholding Adaptativo usando região de 7x7 pixels (a) Imagem original (b) Imagem resultante com $T = 0,35$ (c) Imagem resultante com $T = 0,50$ (d) Imagem resultante para $T = 0,70$ . ....	107
Figura 7.9 - Tela de saída do sistema segmentação: linearização do histograma da imagem. ....	108
Figura 7.10 - Tela de saída do sistema de segmentação – técnica imagem-diferença. ....	108
Figura 7.11 - Tela de saída do sistema: "thresholding" adaptativo. ....	109
Figura 7.12 - Tela do sistema com a relação de atributos de textura e de contraste e distribuição das microcalcificações. ....	110
Figura 7.13 - Tela do sistema com a relação de atributos de forma das microcalcificações. ....	110
Figura 7.14 - Exemplo de tela de saída do sistema de seleção de atributos - erro de Bayes. ....	111
Figura 7.15 - Exemplo de relatório gerado pela etapa de seleção de atributos – erro de Bayes. ....	112
Figura 7.16 - Exemplo de tela de saída do sistema de seleção de atributos – distância JM. ....	113
Figura 7.17 - Exemplo de relatório gerado pela etapa de seleção de atributos – distância de Jeffries-Matusita. ....	113
Figura 7.18 - Curva ROC obtida para o classificador linear de Bayes usando os dados das tabelas 7.2 , 7.3, 7.4, 7.5 e 7.6. ....	116
Figura 7.19 - Curva ROC obtida para o classificador linear de Bayes usando os dados das tabelas 7.8, 7.9, 7.10 e 7.11. ....	119
Figura 7.20 - Curva ROC obtida para o classificador linear de Bayes usando os dados das tabelas 7.13 , 7.14, 7.15, 7.16 e 7.17. ....	123
Figura 7.21 - Curva ROC obtida para o classificador linear de Bayes usando os dados das tabelas 7.18 , 7.19, 7.20, 7.21 e 7.22. ....	126
Figura 7.22 - Curva ROC obtida variando-se o valor de k e o limiar $M_B$ (de 5 a 19) com o limiar $M_M$ fixo em 1 - dados da tabela 7.25. ....	131
Figura 7.23 - Curva ROC obtida variando-se os limiares $M_B$ (de 1 a 11) e $M_M$ (de 11 a 1) - dados da tabela 7.27. ....	131

# Índice de Tabelas

## CAPÍTULO 1

Tabela 1.1 - Índice de malignidade associado à forma das microcalcificações - [GAL-84].	3
---	---

## CAPÍTULO 2

Tabela 2.1 - Número de pontos e área sob a curva ROC para detecção de microcalcificações individuais - [WOODS-94].	19
Tabela 2.2 - Ponto de operação para detecção de microcalcificações e taxa de detecção dos melhores agrupamentos - [WOODS-94].	19
Tabela 2.3 - Atributos utilizados na classificação de microcalcificações - [PARKER-93].	26
Tabela 2.4 - Novos atributos utilizados na classificação de microcalcificações - [PARKER-94].	27
Tabela 2.5 - Resultados da classificação de <i>comedo</i> carcinomas, utilizando-se várias combinações de atributos - [PARKER-94].	28
Tabela 2.6 - Resultados da classificação de 143 calcificações para diferentes combinações dos fatores de forma propostos - [SHEN-94].	29

## CAPÍTULO 6

Tabela 6.1 - Número de amostras utilizadas para treinamento e testes dos classificadores – método “leave-k-out”.	71
Tabela 6.2 - principais parâmetros usados no treinamento das RNAs.	94
Tabela 6.3 - Possibilidades de respostas em um experimento de teoria de detecção de sinal.	97

## CAPÍTULO 7

Tabela 7.1 - Resultado da seleção usando o erro de Bayes e distância de Jeffries-Matusita. Atributos apresentados em ordem crescente de área média de sobreposição calculada para os 4 grupos de treinamento.	111
Tabela 7.2 - Avaliação do classificador linear através da variação dos custos do FP e FN, mantendo $P(B)=P(M)=50\%$ .	114
Tabela 7.3 - Avaliação do classificador linear através da variação dos custos do FP e FN, mantendo $P(B)=60\%$ e $P(M)=40\%$ .	115

Tabela 7.4 - Avaliação do classificador linear através da variação dos custos do FP e FN, mantendo $P(B)=70\%$ e $P(M)=30\%$ .....	115
Tabela 7.5 - Avaliação do classificador linear através da variação dos custos do FP e FN, mantendo $P(B)=80\%$ e $P(M)=20\%$ .....	115
Tabela 7.6 - Avaliação do classificador linear através da variação dos custos do FP e FN, mantendo $P(B)=90\%$ e $P(M)=10\%$ .....	116
Tabela 7.7 - Avaliação do classificador linear através da variação das probabilidades $P(B)$ e $P(M)$ , para o critério de máxima probabilidade <i>a posteriori</i> .....	117
Tabela 7.8 - Avaliação do classificador linear através da variação das probabilidades $P(B)$ e $P(M)$ , mantendo $C(FP)=10\%$ e $C(FN)=90\%$ . ....	117
Tabela 7.9 - Avaliação do classificador linear através da variação das probabilidades $P(B)$ e $P(M)$ , mantendo $C(FP)=20\%$ e $C(FN)=80\%$ . ....	117
Tabela 7.10 - Avaliação do classificador linear através da variação das probabilidades $P(B)$ e $P(M)$ , mantendo $C(FP)=30\%$ e $C(FN)=70\%$ . ....	118
Tabela 7.11 - Avaliação do classificador linear através da variação das probabilidades $P(B)$ e $P(M)$ , mantendo $C(FP)=40\%$ e $C(FN)=60\%$ . ....	118
Tabela 7.12 - Avaliação do classificador linear através da variação das probabilidades de ocorrência das classes. Mínimo erro para limiar de rejeição $\lambda=0,30$ e matriz de custos 0-1.....	119
Tabela 7.13 - Avaliação do classificador quadrático através da variação dos custos do FP e FN, mantendo $P(B)=P(M)=50\%$ .....	121
Tabela 7.14 - Avaliação do classificador quadrático através da variação dos custos do FP e FN, mantendo $P(B)=60\%$ e $P(M)=40\%$ .....	122
Tabela 7.15 - Avaliação do classificador quadrático através da variação dos custos do FP e FN, mantendo $P(B)=70\%$ e $P(M)=30\%$ .....	122
Tabela 7.16 - Avaliação do classificador quadrático através da variação dos custos do FP e FN, mantendo $P(B)=80\%$ e $P(M)=20\%$ .....	122
Tabela 7.17 - Avaliação do classificador quadrático através da variação dos custos do FP e FN, mantendo $P(B)=90\%$ e $P(M)=10\%$ .....	123
Tabela 7.18 - Avaliação do classificador quadrático através da variação das probabilidades $P(B)$ e $P(M)$ , para o critério de máxima probabilidade <i>a posteriori</i> . ....	124
Tabela 7.19 - Avaliação do classificador quadrático através da variação das probabilidades $P(B)$ e $P(M)$ , mantendo $C(FP)=10\%$ e $C(FN)=90\%$ . ....	124
Tabela 7.20 - Avaliação do classificador quadrático através da variação das probabilidades $P(B)$ e $P(M)$ , mantendo $C(FP)=20\%$ e $C(FN)=80\%$ . ....	124
Tabela 7.21 - Avaliação do classificador quadrático através da variação das probabilidades $P(B)$ e $P(M)$ , mantendo $C(FP)=30\%$ e $C(FN)=70\%$ . ....	125
Tabela 7.22 - Avaliação do classificador quadrático através da variação das probabilidades $P(B)$ e $P(M)$ , mantendo $C(FP)=40\%$ e $C(FN)=60\%$ . ....	125

Tabela 7.23 - Avaliação do classificador linear através da variação das probabilidades de ocorrência das classes. Mínimo erro para limiar de rejeição $\lambda=0,30$ e matriz de custos 0-1.....	126
Tabela 7.24 - Método k-NN: Classificação sem rejeição e baixa sensibilidade.....	129
Tabela 7.25 - Método k-NN: Classificação sem rejeição e alta sensibilidade.....	129
Tabela 7.26 - Método k-NN: Classificação com rejeição e alto grau de certeza.....	130
Tabela 7.27 - Método k-NN: Classificação sem rejeição variando o limiar de decisão.....	130
Tabela 7.28 - Rede MLP - uma camada intermediária com diferentes números de neurônios – com rejeição.....	133
Tabela 7.29 - Rede MLP - duas camadas intermediárias com diferentes números de neurônios – com rejeição.....	133
Tabela 7.30 - Rede MLP - uma camada intermediária com diferentes números de neurônios – sem rejeição. ....	134
Tabela 7.31 - Rede MLP - duas camadas intermediárias com diferentes números de neurônios – sem rejeição. ....	134

# Capítulo 1

## Introdução

O câncer de mama é atualmente a doença que lidera o número de mortes em mulheres em grande parte do mundo, conforme afirmam D. H. Davies e D.R.Dance [DAVIES-90]. Ainda de acordo com Davies, o câncer de mama apresenta a maior taxa de mortalidade entre todos os tipos de câncer na Europa Ocidental e na América do Norte. No Canadá, segundo Liang Shen *et al.* [SHEN-93A], estatísticas indicam que uma entre dez mulheres desenvolverão esta doença durante o seu período de vida. Nos Estados Unidos, de acordo com o trabalho apresentado por Edward A. Patrick *et al.* [PATRICK-91], são registrados 112.000 casos de câncer de mama por ano, havendo mais de 37.000 mortes. Também, estatísticas realizadas pelo “National Alliance of Breast Cancer Organizations” indicam que o câncer de mama é o tipo de câncer que mais mata mulheres africanas e americanas.

Por essas razões, várias pesquisas foram direcionadas para o desenvolvimento de métodos mais eficientes para a detecção e tratamento desse tipo de câncer. Infelizmente, a cura do câncer de mama ainda não é possível, pois suas causas não foram completamente determinadas. Desta forma, a detecção precoce e a remoção do tumor na fase inicial é hoje a estratégia mais eficiente na redução da taxa de mortalidade dos pacientes ( [SHEN-93A] ). Segundo Andrew F. Laine, Jian Fan e Wuhai Yang [LAINE-95], estatísticas efetuadas a partir de mulheres americanas com câncer de mama mostraram que as taxas de sobrevivência por 5 anos geralmente são maiores, em torno de 93%, para o câncer de mama detectado no estágio inicial, caindo para 72% em estágios intermediários e apenas 18% para estágios finais.

No entanto, a detecção precoce realizada por especialista através da análise visual é muito difícil devido a baixa qualidade apresentada pelos mamogramas. Os problemas apresentados pelos mamogramas são devidos principalmente a absorção pouco diferenciada entre os tecidos que compõem a mama e a efeitos físicos de aquisição da imagem, como: dimensão do ponto focal, efeito

Heel, [CURRY-III-90], [MARQUES-98], radiação espalhada e sobreposição de estruturas, entre outros. Dessa forma, o uso de sistemas de diagnóstico auxiliado por computador (sistemas CAD) pode, através de técnicas computacionais específicas, realçar características de interesse na imagem (microcalcificações e nódulos), como também efetuar a classificação de lesões de mama, dando mais confiança à tomada de decisão realizada pelos especialistas.

## **1.1 - A importância da mamografia**

Dos métodos de diagnóstico atualmente disponíveis, a mamografia é ainda o mais eficaz para a detecção do câncer precoce, sendo esta constatação feita por vários autores, entre eles, William M. Morrow e Ramam B. Paranjape [MORROW-92], Françoise Lefebvre *et al.* [LEFEBVRE-94] e Nicholas Petrick *et al.* [PETRICK-96]. Isso porque a mamografia possui os requisitos necessários para a obtenção de imagens de lesões pequenas. A mamografia com sistema tela-filme apresenta altas resoluções (espacial e de contraste) que são fundamentais no registro de microcalcificações mamárias. Entretanto, segundo Catherine M.Kocur *et al.* [KOCUR-96], 10 a 30% dos cânceres de mama, incluindo os tumores palpáveis, não são detectados com a rotina mamográfica. Dois terços desses falso-negativos são evidenciados através de uma revisão detalhada dos mamogramas anteriores. Esses falso-negativos podem ser atribuídos a vários fatores, incluindo baixa qualidade da imagem, fadiga do radiologista e descuido humano.

## **1.2 - Principais indicadores de lesões de mama**

Segundo Walter B. Richardson Jr. [RICHARDSON-95], os radiologistas utilizam características de dois sinais principais para a discriminação entre os tecidos normais e com câncer (ver Figura 1.1). O primeiro sinal é a massa, nódulo ou neoplasma, sendo analisados a forma e a densidade radiográfica. O



neoplasma benigno possui bordas mais suaves enquanto a malignidade é caracterizada pela borda irregular (forma espicular). As imagens da Figura 1.1 (c) e (d) ilustram nódulos com contornos bem definidos enquanto as Figuras 1.1 (e) e (f) apresentam nódulos com contornos irregulares. O segundo sinal é a microcalcificação, caracterizada, segundo R. L. Egan [EGAN-80] e K. S. Woods [WOODS-94], por depósitos de cálcio de formatos e tamanhos variados. As Figuras 1.1 (a) e (b) apresentam, dois casos de agrupamentos de microcalcificações associados a tumores maligno e benigno, respectivamente.

Muitos dos casos iniciais de câncer de mama são atualmente descobertos pela detecção de microcalcificações, segundo A. P. Dhawan, Yateen Chitre e Myron Moskowitz [DHAWAN-93]. Embora, os nódulos e as microcalcificações sejam os sinais mais comuns apresentados por lesões de mama, existem ainda muitos outros indicadores, como distorções do parênquima mamário, assimetria entre as mamas esquerda e direita e enrugamento da pele da mama. De acordo com [DAVIES-90], aproximadamente 50% dos carcinomas possuem microcalcificações associadas visíveis no mamograma e entre 50 e 80% dos carcinomas de mama revelam microcalcificações sob exame histológico.

Em um artigo publicado em 1984, Michele Le Gal, Guy Chavanne e Daniel Pellier [GAL-84] classificam as microcalcificações obtidas de biópsias de tumores de mama de acordo com sua forma, associando um índice de malignidade a cada uma das formas encontradas, conforme a Tabela 1.1.

Forma das microcalcificações	Índice de Malignidade Associado
Forma de anel (“anelar”)	0 %
Pontos Regulares	20 %
Grãos de poeira (muito pequenos para reconhecer a forma)	60 %
Pontos Irregulares	60 %
Forma de Verme (“vermiforme”) ou Ramificada	100 %

**Tabela 1.1 - Índice de malignidade associado à forma das microcalcificações - [GAL-84].**



(a)



(b)



(c)



(d)



(e)



(f)

**Figura 1.1 - Alguns exemplos dos principais sinais utilizados por radiologistas. a, b - agrupamentos de microcalcificações, c, d - nódulos com contornos bem definidos, e, f - nódulos com contornos irregulares.**

Entretanto, segundo Joachim Dengler, Sabine Behrens e Johann Friedrich Desaga [DENGLER-93], a análise da forma das microcalcificações exige grande experiência do radiologista para um diagnóstico preciso devido as dimensões reduzidas e ao baixo contraste dessas estruturas. Mesmo para um radiologista com grande experiência, as microcalcificações podem passar despercebidas no processo de visualização, uma vez que o sistema de raios-X apresenta várias limitações que prejudicam a imagem, tais como: ruídos aleatórios, variações nas características do filme e tamanho do ponto focal acima da especificação necessária em algumas situações, entre outros.

A dificuldade na visualização das microcalcificações causa um aumento significativo no número de biópsias realizadas. De acordo com [DHAWAN-93], a taxa de falso-positivos utilizando as microcalcificações como um sinal indicativo de biópsia, é de 0.88 (número de falso-positivos dividido pela soma do número de falso-positivos e falso-negativos), resultando em 260.000 novos casos de biópsias desnecessárias por ano. A redução na taxa de falso-positivos não apenas economiza uma grande quantidade de recursos financeiros, mas principalmente evita o trauma para o paciente e uma cicatriz desnecessária que poderá prejudicar futuros exames. No entanto, a redução do número de falso-positivos deve ser realizada mantendo-se a sensibilidade do sistema de diagnóstico.

Nesse contexto, os sistemas desenvolvidos para auxílio ao diagnóstico médico podem se tornar uma ferramenta extremamente importante. Tais sistemas buscam detectar e/ou classificar automaticamente as microcalcificações, ou agrupamentos de microcalcificações, fornecendo uma segunda opinião aos radiologistas. Num sistema CAD típico, o mamograma digitalizado é submetido a filtros e algoritmos para correção de fundo. Após esta etapa, as microcalcificações são segmentadas e por último são extraídas as características utilizadas na classificação da imagem. A etapa de segmentação deve ser suficientemente bem elaborada para conseguir separar as microcalcificações das demais estruturas presentes na imagem, sem contudo perder as suas características morfológicas, ([DHAWAN-93]), ([WOODS-94]). A partir das informações extraídas das regiões de interesse (ROIs) e das microcalcificações contidas na imagem do mamograma digitalizado, a lesão de mama é classificada como benigna ou maligna. A etapa de classificação pode ser subdividida em 3 partes principais: a extração das

características (ou atributos) da imagem, seleção dos principais atributos e a classificação propriamente dita.

Nessa pesquisa, são analisados algoritmos tanto para a segmentação quanto para a classificação de regiões suspeitas com microcalcificações na imagem digitalizada do mamograma.

### 1.3 - Objetivos da Pesquisa

O principal objetivo deste trabalho de pesquisa é desenvolver algoritmos computacionais que possam ser utilizados para a classificação, em maligna ou benigna, de regiões suspeitas do mamograma contendo microcalcificações.

O sistema desenvolvido deve ser capaz de realizar a classificação da imagem de forma sistemática a partir de valores mensuráveis (atributos) extraídos da imagem digitalizada do mamograma. Para isso, diferentes atributos serão investigados, levando-se em consideração a forma das microcalcificações, informações de textura e contraste da imagem, e demais medidas relevantes na diferenciação entre as classes.

Também deverão ser analisadas técnicas que permitam selecionar o melhor subgrupo de medidas entre as implementadas. Esse subgrupo será utilizado para a realização da classificação das imagens.

Diferentes tipos de classificadores deverão ser investigados para a classificação da imagem, sendo suas principais características usadas em favor do problema em questão. Por fim, os resultados obtidos pelos diversos métodos deverão ser comparados entre si para determinar as principais vantagens e desvantagens dos métodos.

É importante ressaltar que o objetivo dessa pesquisa não é propor um sistema de classificação que substitua a análise do médico, mas sim um sistema que o auxilie na tomada de decisão.

## **1.4 - Contribuições do Trabalho**

Essa pesquisa contribuiu para a realização de uma base de dados de imagens para treinamento e avaliação de métodos de processamento voltados para a classificação de lesões de mama.

Outra importante contribuição é dada através da avaliação de classificadores que possibilitam a inserção da classe rejeição. Essa abordagem é importante em sistemas de auxílio ao diagnóstico médico, uma vez que os casos rejeitados podem ser melhor analisados para a determinação de novas medidas capazes de discriminá-los.

A pesquisa foi dirigida para o desenvolvimento de um sistema de auxílio médico o que é relevante considerando a tarefa tão complexa que é a classificação de uma lesão de mama a partir da análise, única e exclusiva, de uma imagem digitalizada.

O trabalho desenvolvido permitiu a determinação e entendimento de elementos essenciais para a realização da classificação. Dessa forma, a discussão desses elementos, no contexto do problema estudado, pode servir como bases para trabalhos futuros nesta área.

## **1.5 – Organização desta dissertação**

Esta dissertação é dividida em 8 capítulos, além desta introdução. O capítulo 2 apresenta uma revisão bibliográfica sobre a detecção e classificação de microcalcificações em mamogramas digitalizados. Os capítulos 3 e 4 relacionam, respectivamente, os principais atributos e técnicas de classificação encontrados na literatura para a classificação de lesões de mama contendo microcalcificações. O capítulo 5 apresenta as conclusões que foram desprendidas da revisão bibliográfica realizada e como estas conclusões nortearam o trabalho de pesquisa. O capítulo 6 descreve os materiais e métodos utilizados na implementação dos algoritmos computacionais. O capítulo 7 apresenta os resultados alcançados em cada etapa do

sistema. Finalmente, no capítulo 8 encontram-se as conclusões do trabalho realizado como também indicações de sugestões para futuras investigações sobre o assunto.

# Capítulo 2

## **Estado da Arte na Detecção e Classificação de microcalcificações em imagens mamográficas**

Nos últimos 20 anos o número de trabalhos na área de processamento de imagens médicas, voltados à detecção e classificação de lesões de mama a partir de mamogramas digitalizados, têm aumentado exponencialmente. Isso se deve principalmente, aos avanços tecnológicos que hoje permitem o processamento de grande volume de dados num tempo muito reduzido. Os principais trabalhos nesta área, podem ser apresentados de acordo com as técnicas empregadas no processamento da imagem. As técnicas podem ser divididas em três categorias: pré-processamento, detecção/segmentação e classificação. Este estudo dará maior ênfase à classificação das microcalcificações divididas em dois grupos: microcalcificações associadas à lesões de mama malignas e benignas.

A etapa de pré-processamento busca melhorar a qualidade da imagem a ser processada pelas etapas seguintes e/ou para facilitar a análise visual realizada por especialistas. Geralmente ela atua de forma a minimizar os ruídos existentes e realçar determinadas estruturas ou características de interesse na imagem.

A etapa de detecção/segmentação, apresentada na seção 2.1, busca encontrar as estruturas de interesse (microcalcificações, agrupamentos de microcalcificações) dentro da imagem e separá-las dos demais componentes da imagem. A detecção automática dessas estruturas é uma tarefa importante, pois, muitas vezes elas passam despercebidas à análise do radiologista. Nesta etapa, o algoritmo deve detectar o maior número possível dessas estruturas, sem contudo, interpretar ruídos como sinais verdadeiros. Um outro fator importante, no caso de microcalcificações, é a preservação da forma, pois esta informação pode ser utilizada na classificação da lesão de mama.

Por fim, após as estruturas de interesse terem sido separadas da imagem da mama, várias medidas (de caráter morfológico, estruturais, etc.) são

realizadas sobre elas, a fim de representá-las da forma mais precisa possível. Além de medidas efetuadas sobre as microcalcificações (agrupadas ou isoladas), alguns trabalhos efetuam a classificação da imagem em lesão benigna ou maligna a partir de informações de textura, extraídas das ROIs da imagem, sem a necessidade da etapa de detecção/segmentação. Essas medidas são realizadas e organizadas separadamente para imagens de lesões malignas e benignas, e devem ser suficientemente representativas e discriminatórias para as duas classes. Os vetores de atributos rotulados, são então utilizados para o treinamento e testes do classificador implementado. Os principais trabalhos relacionados a esta etapa estão apresentados nas seções 2.2 e 2.3, de acordo com as estruturas classificadas (microcalcificações e agrupamentos de microcalcificações) e as técnicas utilizadas na classificação.

De uma forma geral, a maior parte dos trabalhos relacionados nas seções 2.1, 2.2 e 2.3, realizam *a priori*, uma etapa de aquisição de dados, obtendo informações para a elaboração de uma base de imagens com os respectivos laudos de biópsia. A seguir, as imagens são processadas por algoritmos que realizam o pré-processamento, a detecção/segmentação e a classificação da imagem. Por fim, os resultados são comparados com as informações dos laudos de biópsias ou com a opinião de especialistas experientes, a partir de técnicas de análise de desempenho. Entretanto, segundo Robert M. Nishikawa *et al.* [NISHIKAWA-92], uma comparação direta entre os resultados obtidos através das diversas técnicas utilizadas é muito difícil, uma vez que cada grupo de pesquisa utiliza uma base de dados diferente. Em um trabalho apresentado em 1994 por H. P. Chan *et al.* [CHAN-94], os autores demonstram que as características da base de dados são também fatores importantes; resolução espacial e número de níveis de cinza utilizados influem diretamente nos resultados obtidos, principalmente quando as estruturas analisadas são pequenas.



## 2.1 - Detecção e Segmentação de microcalcificações

Em 1992, Robert M. Nishikawa *et al.* [NISHIKAWA-92], desenvolveram uma técnica para a detecção automática de agrupamentos de microcalcificações em mamogramas digitalizados. O método desenvolvido consiste de 3 etapas. Na primeira, a relação sinal-ruído da microcalcificação é melhorada através de filtros que reduzem as estruturas de fundo da imagem. Na segunda etapa, as microcalcificações são identificadas pelo uso de um “threshold” de níveis de cinza e erosão morfológica sobre a imagem global. Por fim é aplicada uma técnica de “thresholding” de níveis de cinza local adaptativa. Na terceira e última etapa, o número de sinais falso-positivos são reduzidos através da análise do espectro de potência dos sinais individuais, determinando a distribuição espacial do sinal e observando o relacionamento entre tamanho, forma e valores dos pixels de fundo das microcalcificações. Neste trabalho os autores utilizaram 78 mamogramas; metade deles contendo agrupamentos de microcalcificações e a outra metade sem nenhum agrupamento presente.

Usando esta abordagem, o esquema proposto foi capaz de detectar, segundo os autores, 87% dos agrupamentos verdadeiros com uma média de 2 agrupamentos falso-positivos por imagem.

No ano seguinte, Robert M. Nishikawa, Maryellen L. Giger, Kunio Doi, Carl J. Vyborny e Robert A. Schmidt [NISHIKAWA-93A], apresentaram um novo artigo, propondo uma nova técnica para a detecção de agrupamentos de microcalcificações. O método, chamado de “transformação recursiva área ponto”, ou transformação AP, tem por objetivo transformar microcalcificações individuais em pixels, com o intuito de facilitar a contagem de sinais no momento da identificação do agrupamento.

A transformação é realizada por uma máscara que passa pela imagem, e a cada posição calcula o número de pixels com nível de cinza superior ao do fundo da imagem. Havendo dois ou mais pixels com essa característica, todos os pixels sob a máscara são ajustados para um valor igual ao do fundo, menos o pixel do canto inferior direito da máscara, que é ajustado para o valor máximo. A máscara é então

movida 2 pixels à direita e o processo é repetido. A imagem é usada para ambos, entrada e saída, e dessa forma, a transformação age de forma recursiva. O resultado da transformação é uma imagem binária, onde os pixels representam sinais que podem ter mais que um pixel na imagem original.

Esse método foi aplicado numa base de dados de 78 mamogramas contendo 41 agrupamentos de microcalcificações. A sensibilidade obtida através dessa técnica, segundo os autores, foi de 85% para uma taxa de agrupamentos falso-positivos de 2.5 por imagem.

Ainda em 1993, os mesmos autores apresentaram um artigo, [NISHIKAWA-93B], propondo um pacote de técnicas para auxiliar o diagnóstico de radiologistas. Este pacote incluiu algoritmos para detecção e classificação (benigno vs. maligno) automáticas de microcalcificações e nódulos, e ainda técnicas para a identificação de indicadores secundários, como enrugamento da pele da mama. Para a detecção das microcalcificações os autores utilizaram os mesmos procedimentos apresentados em [NISHIKAWA-92], porém uma rede neural invariante ao deslocamento foi implementada a fim de reduzir o número de falso-positivos. De acordo com Robert M. Nishikawa *et al.*, a rede neural foi capaz de eliminar 70% de agrupamentos falso-positivos, sem qualquer perda de detecção dos verdadeiro-positivos.

Em um artigo publicado em 1992, Yuzheng Wu, Kunio Doi, Maryellen L. Giger e Robert M. Nishikawa em [WU-92], apresentam um método de detecção de agrupamentos de microcalcificações em mamogramas a partir da análise de regiões de interesse. O método é dividido em três etapas: a primeira efetua um pré-processamento nas ROIs para isolar as microcalcificações das estruturas de fundo, a segunda etapa prepara as ROIs para a classificação e a terceira realiza a classificação das ROIs através de uma rede neural artificial (RNA).

Na etapa de pré-processamento é aplicada a técnica de correção de fundo direcionado (“background-trend correction”) ([KATSURAGAWA-88]), utilizando-se uma curva polinomial bidimensional ajustável, para compor uma superfície de fundo para cada região de interesse. A superfície de fundo ajustada é então subtraída da ROI original produzindo uma nova região com fundo corrigido.

Depois dessa etapa, todas as regiões selecionadas têm o mesmo nível de fundo e o mesmo valor de pixel médio.

Na segunda etapa, a preparação das ROIs para a classificação é efetuada de duas maneiras: um tratamento no domínio da frequência, com o cálculo do espectro de frequência através da transformada de Fourier e escalonamento, e um tratamento no domínio espacial através do escalonamento. No domínio da frequência, antes do escalonamento, o espectro de frequência é convertido para a escala logarítmica a fim de reduzir a variação dinâmica dos dados. O escalonamento simplesmente transforma os dados para a faixa entre 0 e 1.

Na terceira e última etapa, para classificar as ROIs os autores utilizam uma RNA “feedforward” com três camadas, função de ativação do tipo logística não linear e treinada pelo algoritmo “backpropagation”.

Os algoritmos foram testados em 60 ROIs de 8x8 pixels, extraídas de 3 mamogramas, para a obtenção de microcalcificações isoladas. A extração foi efetuada visualmente sendo que metade das ROIs continham microcalcificações e a outra metade não. Outras 168 ROIs, de 32x32 pixels, extraídas de 34 mamogramas, foram utilizadas para a obtenção de agrupamentos de microcalcificações. Dessas 168 ROIs, 56, selecionadas visualmente, continham agrupamentos (ROIs positivas), 56 não continham (ROIs negativas) e as outras 56 são regiões falso-positivas, registradas pelo método de detecção automática descrito em [NISHIKAWA-90].

A rede apresentou 100% de acerto, quando utilizada para detectar os agrupamentos, com os quais ela foi treinada. Já quando aplicada a casos diferentes ela não obteve a mesma eficiência, porém apresentou uma melhor resposta para a detecção de agrupamentos do que sinais isolados. Neste caso analisando-se as curvas ROC (“Receiver Operating Characteristic”) traçadas para o sistema, Yuzheng Wu *et al.* concluem que o método pode eliminar até 50% de agrupamentos falso-positivos, preservando 95% dos verdadeiro-positivos. A maior dificuldade com este tipo de técnica, segundo os autores, é a necessidade de uma grande base de dados para o treinamento da rede, de modo a aumentar sua precisão.

Em 1994, W.Zhang, K.Do, M.L.Giger, Y.Wu, R.M.Nishikawa e R.A.Schmidt [ZHANG-94], utilizando o sistema de diagnóstico auxiliado por

computador, descrito em [WU-92], implementaram uma rede neural artificial invariante ao deslocamento para eliminar a detecção de falso-positivos.

A rede desenvolvida é do tipo “feedforward” com duas camadas escondidas e interconexões espacialmente invariantes, funções de ativação do tipo “sigmoid” bipolar e treinada a partir do algoritmo “backpropagation” modificado. A rede foi treinada para detectar microcalcificações individuais numa dada região de interesse. A ROI é classificada como positiva se o número total de microcalcificações detectadas for maior que um determinado número. O desempenho da rede foi avaliado através dos métodos “jackknife” (ou “holdout”) e análise de curvas ROC, usando a mesma base de dados e seleções das imagens descritas em [WU-92].

De acordo com os autores, a nova técnica acrescentou mais precisão ao método proposto por Y.Wu *et al.* em [WU-92], que utiliza uma rede neural convencional de 3 camadas “feedforward”, pois as análises indicaram uma área média sobre a curva ROC de 0.91. Aproximadamente 55% das ROIs falso-positivas foram eliminadas sem qualquer perda dos verdadeiro-positivos.

Outra técnica para a detecção de microcalcificações foi proposta por Heang-Ping Chan, Kunio Doi, Simranjit Galhotra, Carl J. Vyborny, Heber MacMahon e Peter M. Jokich [CHAN-87]. O método é baseado na técnica de subtração de imagens, onde uma imagem com as microcalcificações suprimidas, através de filtros, é subtraída da mesma imagem com as microcalcificações realçadas. Essa técnica é aplicada para a eliminação das estruturas de fundo da imagem. A seguir é aplicada uma técnica para a extração das microcalcificações baseada em “thresholding” e na utilização de características físicas das microcalcificações. Nesse trabalho, os autores utilizaram o método “Monte Carlo” para gerar agrupamentos de microcalcificações simulados, que foram inseridos em imagens normais. De acordo com Heang-Ping Chan *et al.*, este método pode alcançar uma taxa de verdadeiro-positivos de 80% com um agrupamento falso-positivo por imagem.

No ano seguinte, Heang-Ping Chan, Kunio Doi, Carl J. Vyborny, Kwok-Leung Lam e Robert A. Schmidt [CHAN-88A], propuseram uma nova versão do método de detecção automática de agrupamentos, apresentado em [CHAN-87].

Em adição às técnicas de subtração de imagens e "thresholding", os autores incluíram um método de crescimento de região para detectar as microcalcificações. Depois da aplicação desses métodos, o tamanho e o contraste desses sinais são calculados para diferenciar as verdadeiras microcalcificações das falsas, geradas por ruídos. Na avaliação do método foram utilizados 20 mamogramas contendo microcalcificações, sendo conseguida uma taxa de 82% de verdadeiro-positivos com um agrupamento falso-positivo por mamograma.

No mesmo ano, Heang-Ping Chan, Kunio Doi, Kwok-Leung Lam, Carl J. Vyborny, Robert A. Schmidt e Charles E. Metz [CHAN-88B], propuseram uma nova versão do método de detecção automática de agrupamentos, apresentado em [CHAN-87]. Assim como em [CHAN-87] e [CHAN-88A], os autores utilizaram a técnica de subtração de imagens para a eliminação das estruturas de fundo da imagem e "thresholding" para a extração das microcalcificações. A principal característica apresentada neste método com relação ao trabalho anterior, é o uso do espectro de potência dos sinais na diferenciação dos sinais verdadeiros e falsos. Nesse trabalho, os autores utilizaram 20 mamogramas contendo agrupamentos de microcalcificações sutis e conseguiram uma taxa de acerto na detecção de 90% com meio agrupamento falso-positivo por imagem.

Em 1990, Heang-Ping Chan, Kunio Doi, Carl J. Vyborny, Robert A. Schmidt, Charles E. Metz, Kwok-Leung Lam, Toshihiro Ogura, Yuzheng Wu e Heber Macmahon [CHAN-90], apresentaram um programa desenvolvido para localizar automaticamente agrupamentos de microcalcificações em mamogramas digitalizados. O programa detecta microcalcificações de forma muito sensível e tem por objetivo auxiliar radiologistas na identificação de agrupamentos de microcalcificações suspeitos. O método proposto neste artigo é semelhante ao apresentado em [CHAN-88B]. Para melhorar o desempenho da detecção, os autores incluíram neste trabalho um novo critério para a extração do sinal. Para cada microcalcificação que satisfaça o critério de tamanho e contraste, o espectro de potência é calculado numa região de  $n \times n$  pixels, com a microcalcificação no centro dessa região. A seguir, é aplicado um método de correção de fundo utilizando uma curva polinomial ajustada a partir dos valores dos pixels da região. Depois dessa correção o espectro de potência é calculado para cada região através da transformada de Fourier. Os espectros de potência dos sinais verdadeiros e falsos, caracterizados

pelo primeiro momento e calculados para 47 mamogramas, são utilizados para identificar as microcalcificações. Para a análise dos resultados foram utilizados 60 mamogramas, constatando-se uma taxa de 87% de verdadeiro-positivos com 4 agrupamentos falso-positivos por mamograma.

Em um artigo publicado em 1994, K.S.Woods, J.L.Solka, C.E.Priebe, W.P. Kegelmeyer, C.C. Doss e K.W. Bowyer [WOODS-94], realizaram um estudo comparativo entre sete técnicas de classificação para uso na detecção automática de microcalcificações em mamogramas digitalizados. Neste trabalho os classificadores avaliaram se os objetos segmentados eram ou não calcificações. Depois foi aplicado um pós-processamento para determinar a presença ou não de agrupamentos de microcalcificações. A comparação dos métodos foi efetuada através de curvas ROC.

Os classificadores examinados foram: dois classificadores Bayesianos ( classificador linear (CL) e o classificador quadrático (CQ) ), um classificador de árvore de decisão binária (CADB), três redes neurais artificiais e um classificador K-NN (“K-nearest-neighbor” ou K-vizinho mais próximo).

A obtenção dos dados para treinamento e teste dos classificadores, foi realizada por uma etapa de segmentação, a qual iniciou-se com o realce do contraste da imagem para localizar as possíveis microcalcificações, seguida por um algoritmo de crescimento de região e um “threshold” global, que eliminou alguns dos falsos sinais.

O resultado da rotina de segmentação é uma máscara para cada imagem, indicando as localizações das possíveis microcalcificações, chamadas de candidatas. Uma vez determinada as localizações das estruturas candidatas, um grupo de sete atributos foi escolhido e seus valores calculados para cada uma delas e organizados num vetor, sendo este normalizado e armazenado num arquivo.

Para desenvolver e avaliar os métodos de classificação, um grupo de 24 mamogramas, cada um contendo no mínimo um agrupamento de microcalcificações analisado por biópsia, foi digitalizado com resolução de 70  $\mu\text{m}$ . As imagens foram divididas em dois grupos: um de treinamento, com 9 imagens e outro para testes, contendo 15 imagens. Todas as sete técnicas de classificação utilizaram o mesmo grupo de treinamento.

Foram extraídos um total de 29 atributos, dos quais 7 permaneceram para o estudo. Na seleção dos atributos os autores levaram em consideração a correlação existente entre eles e a capacidade que cada atributo tem em separar uma classe da outra. Os 7 atributos selecionados foram:

- a) área do objeto em pixels
- b) nível médio de cinza
- c) gradiente dos pixels do perímetro
- d) raiz quadrada média (rms) da flutuação do ruído do objeto
- e) flutuação de ruído (rms) em uma área de  $3.5\text{mm}^2$  do fundo local
- f) contraste
- g) momentos de baixa ordem.

Dentre as 3 RNAs utilizadas, duas delas são auto-organizantes (“Correlação de Cascata” e “Divide e Conquista”), possuindo arquiteturas ajustadas em tempo de execução, a outra é do tipo “feedforward” treinada pelo algoritmo “backpropagation”. A RNA “feedforward - backpropagation”, foi treinada e testada com vários nós (5 a 20 por camada), e várias camadas escondidas. A melhor taxa de detecção foi encontrada para 10 nós e 2 camadas escondidas.

A técnica K-NN foi ajustada a partir de dois parâmetros; o número de vizinhos próximos para base de decisão, e o valor de “threshold” “k” que determina se um objeto desconhecido deve ser classificado como microcalcificação ou não.

Os classificadores CL e CQ foram desenvolvidos a partir da determinação dos parâmetros, vetor de médias e matriz de covariância, obtidos a partir do grupo de amostras de treinamento. Uma vez determinados os parâmetros, os modelos são utilizados para estimar as densidades de probabilidade condicionais das classes,  $p(\mathbf{x}|C_i)$ , de uma amostra desconhecida. O critério de decisão foi baseado na razão de verossimilhança  $p(\mathbf{x}|C_0)/p(\mathbf{x}|C_1)$ . Os autores ajustaram um limiar de decisão “T” de forma que: se a razão de verossimilhança for maior que “T” a amostra desconhecida é classificada como microcalcificação, caso contrário ela é rotulada como não sendo uma microcalcificação. As curvas ROC foram obtidas variando “T” de 0 a 15 com incrementos de 0.01.

Para o classificador CADB, os pontos da curva ROC foram obtidos pela simples variação de um “threshold” sobre alguns intervalos dos nós terminais da árvore. Para comparar os resultados das diversas técnicas de classificação, a curva ROC foi obtida, no caso da classificação de calcificações individuais, para cada uma das técnicas. A Figura 2.1 ilustra os resultados das curvas ROC para os cinco melhores classificadores, no caso da detecção de agrupamentos:

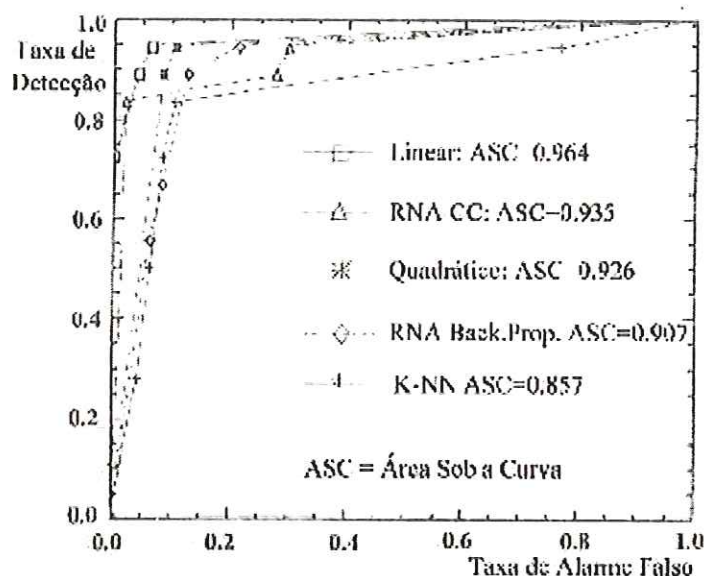


Figura 2.1 - Curvas ROC para detecção de agrupamentos de microcalcificações [WOODS-94]

Os autores concluem que o classificador linear é o método mais efetivo, tanto para calcificações individuais quanto para agrupamentos, embora ele seja um dos mais simples. No primeiro caso a área sob a sua curva ROC chega a 0.936 e o seu melhor ponto de operação possui uma taxa de verdadeiro-positivo (TP) de 73% para uma taxa de falso positivo (FP) de 3,5%, conforme tabelas 2.1 e 2.2. Segundo os autores isto se deve ao fato da distribuição do vetor de atributos ser razoavelmente bem descrita por uma distribuição Gaussiana. Também concluem que uma moderada taxa de TP (75%) para detecção de calcificações individuais pode gerar altas taxas para detecção de agrupamentos (TP = 95%).



Classificador	Número de Pontos na Curva ROC	Área sob a curva ROC
Classificador Linear	60	0.936
RNA-Feedforward Backpropagation	75	0.935
K-NN	17	0.929
Classificador Quadrático	42	0.918
RNA "Correlação de Cascata"	70	0.918
Árvore de Decisão Binária	6	0.900
RNA "Divide e Conquista"	57	0.887

Tabela 2.1 - Número de pontos e área sob a curva ROC para detecção de microcalcificações individuais - [WOODS-94]

Classificador	Ponto de Operação (VP %, alarme falso %)	Agrupamentos VP (18 possíveis)	Agrupamentos FP
Classificador Linear	(73%, 3.5%)	17	3
Classificador Linear	(68%, 2.5%)	16	2
RNA-Correlação de Cascata	(50%, 2.4%)	15	1
Classificador Linear	(49%, 0.8%)	12	0

Tabela 2.2 - Ponto de operação para detecção de microcalcificações e taxa de detecção dos melhores agrupamentos - [WOODS-94]

No mesmo ano, Joachim Dengler *et al.* [DENGLER-93], utilizaram filtros gaussianos combinados com morfologia matemática para a detecção e segmentação de microcalcificações. A técnica apresentada busca preservar o tamanho e a forma das calcificações individuais, da maneira mais exata possível. A abordagem proposta usa um algoritmo de dois estágios para a detecção e a extração da forma dos sinais. No primeiro estágio, são aplicados dois filtros Gaussianos, com diferentes pesos no núcleo, para a detecção de sinais com tamanho específico e invariantes a ruído. No estágio seguinte, um filtro morfológico é utilizado para reproduzir a forma dos sinais. Os resultados de ambos os filtros são combinados com a operação condicional "thickening". A topologia e o número de sinais são determinados pelo primeiro filtro, e a forma através do segundo.

A idéia básica da técnica proposta pelos autores é a obtenção de uma imagem com as microcalcificações suprimidas, porém preservando as estruturas de fundo do mamograma. Esta imagem, é subtraída da original a partir de operações morfológicas, gerando uma terceira imagem que contém apenas as microcalcificações.

Os autores utilizaram 25 imagens para a análise do algoritmo implementado, obtendo, segundo eles, uma sensibilidade de 97% e especificidade de aproximadamente 70%.

## **2.2 - Classificação de microcalcificações isoladas**

Neste grupo, os pesquisadores analisam isoladamente cada microcalcificação (dentro ou não de agrupamentos), extraindo informações de forma, contraste relativo, e outras características que possam representar uma medida de malignidade associada à lesão de mama. A análise individual e cuidadosa da forma e do tamanho das calcificações pode levar os radiologistas a sua localização anatomopatológica e, indiretamente, ao processo que as produziu.

### **2.2.1 – Classificação através da comparação entre atributos**

Em 1972, L.V. Ackerman e E.E.Gose [ACKERMAN-72], a partir de xeroradiogramas digitalizados, desenvolveram quatro medidas de malignidade – calcificação, “spiculation”, rugosidade e forma – que foram aplicadas para identificar regiões suspeitas. A medida calcificação foi caracterizada através do uso de um histograma derivativo da região suspeita, “spiculation” foi medida através do exame das linhas tangentes às formas das lesões, rugosidade consistiu da soma das diferenças absolutas entre os pontos ao longo de uma linha vertical, e a forma foi determinada com o uso da razão perímetro sobre área. Os atributos foram então utilizados para a classificação. Seus resultados, expressos em termos de curvas ROC, foram obtidos com o uso de uma base de dados composta por 60 imagens (30 com

lesões malignas e 30 com lesões benignas) e indicaram que o desempenho dos atributos para a classificação das lesões foi tão bom quanto um radiologista experiente. Embora os resultados tenham sido promissores, os pesquisadores não deram continuidade ao trabalho.

Em 1989, I.E. Magnin *et al* [MAGNIN-89], apresentaram um método de detecção e classificação automática de microcalcificações em mamogramas digitalizados. A imagem analisada é submetida a uma etapa de pré-processamento para a redução do ruído de fundo e melhoria da relação sinal ruído. O pré-processamento inicia-se com o cálculo da função logarítmica para todos os pontos da imagem. Em seguida a imagem é dividida em pequenas regiões não sobrepostas, das quais calcula-se o valor do pixel médio. Por fim, é efetuada a interpolação entre os pixels da imagem e o máximo valor médio calculado. Segundo os autores, a transformação logarítmica é realizada para inverter os efeitos exponenciais causados pela absorção de raios-X.

Após a etapa de pré-processamento, aplica-se um “threshold” adaptativo para extrair as microcalcificações. O uso da técnica adaptativa, de acordo com I.E.Magnin *et al.*, é necessário devido a variação espacial dos níveis de cinza nas estruturas de fundo da imagem.

De cada microcalcificação extraída da imagem, são calculados os seguintes fatores de forma: perímetro, área, grau de compactação, excentricidade, coeficiente de convexidade, vetor de raio médio (VRM) e uma medida de alongamento. Neste trabalho, os autores não implementam nenhum classificador, mas mostram através de dois gráficos (grau de compactação vs. convexidade e alongamento vs. VRM) que esses pares de atributos são eficientes na discriminação entre microcalcificações arredondadas (microcalcificações lobulares) e microcalcificações alongadas e ramificadas (microcalcificações ductais).

Também em 1989, Seiji Yabashi, Masayasu Hata, Kanji Kubo e Taro Ishikawa [YABASHI-89], classificaram lesões de mama através da comparação de características extraídas da imagem do mamograma. De acordo com os autores, a diferença entre lesões de mama benignas e malignas está na distribuição e no número de microcalcificações. Neste trabalho, os autores aplicam uma operação Laplaciana

para realçar as bordas da imagem, e um filtro bidimensional passa baixa para suavização. A seguir, as microcalcificações são extraídas da imagem pela técnica de “threshold”.

A imagem é então dividida em células contendo microcalcificações, e um índice de agregação “W” é obtido para cada célula a partir do número de microcalcificações que ela contém. Para a classificação dos casos em malignos e benignos, são calculados dois atributos. O primeiro é a distância efetiva entre as células com calcificações (Fator Q), e o segundo é a razão entre a mudança no número de células com relação a mudança do nível de “threshold” utilizado para extrair as células (Fator K).

Um número de 37 casos (15 malignos, 14 benignos e 8 normais) são processados para testar o poder discriminatório dos atributos propostos. Para a diferenciação dos casos, os fatores Q e K são calculados para todos os 37 casos e traçados num gráfico bidimensional. Pela análise dos resultados, os autores estabeleceram duas regiões diferentes. Na primeira, os casos benignos e normais ficaram agrupados para valores de K em torno de 0.5 e Q próximos de 1.0. Na segunda região, encontram-se os casos malignos agrupados com valores de K e Q próximos de 0.25.

### **2.2.2 - Classificação utilizando transformada de Hough**

Em um trabalho publicado em 1995, Aledir Silveira Pereira [PEREIRA-95], desenvolveu uma técnica para a detecção e análise de microcalcificações em mamogramas digitalizados. Através da transformada de Hough, o autor detectou microcalcificações “anelares” e “vermiformes”, indicadas assim por Michèle Le Gal *et al.* [GAL-84], e as classificou de acordo com um índice associado a sua forma.

O método desenvolvido possui duas etapas: a segmentação e a classificação. Na primeira etapa, a região de interesse contendo as microcalcificações é binarizada através de um valor de “threshold” obtido do histograma de níveis de cinza da imagem. Após a binarização da imagem, o autor aplica o método da cadeia (“chain code”) para separar os sinais existentes na

imagem. A cada sinal separado da imagem, é aplicada a transformada de Hough para determinar se o mesmo aproxima-se de uma reta (caracterizando microcalcificações “vermiformes”), ou das formas elípticas e circulares (caracterizando microcalcificações “anelares”).

A classificação é efetuada através do número de microcalcificações dos tipos “anelares” e “vermiformes” encontradas na região analisada da imagem. De acordo com o autor, o sistema apresenta um excelente desempenho para detecção de microcalcificações do tipo “vermiformes”.

### 2.2.3 – Classificação através de Métodos Estatísticos

Em 1975, William G. Wee, Myron Moskowitz Wal-Ching Chang, Yeoung-Ching Ting e Seshagirkaio Pemmeraju [WEE-75], desenvolveram um sistema computadorizado para a avaliação de calcificações mamográficas.

Uma etapa de pré-processamento é aplicada as imagens dos mamogramas de baixa qualidade a fim de eliminar efeitos da baixa ou alta exposição de raios-X. A seguir, as áreas de interesse da imagem são separadas e as microcalcificações segmentadas a partir de uma técnica de “thresholding” adaptativo.

Uma vez segmentadas, as microcalcificações são submetidas a uma etapa de extração de atributos da qual são obtidas sete medidas: área da calcificação, nível de cinza médio dos pixels internos à calcificação, contraste em relação a vizinhança, suavidade da área interna, comprimentos vertical e horizontal aproximados, uma medida de forma e o total de buracos dentro da calcificação. As medidas de suavidade e forma, estão descritas no capítulo 3, seção 3.1.5.

Para a classificação, os autores utilizaram um sistema de reconhecimento de padrões desenvolvido em 1971 por William G. Wee [WEE-71], que é uma generalização das funções discriminantes “piecewise-linear”. A matriz de custo utilizada pelo classificador foi  $\begin{bmatrix} 0.1 & 1.0 \\ 3.5 & 0.1 \end{bmatrix}$ , onde os valores 1.0 e 3.5 representam os custos do falso-positivo e do falso-negativo, respectivamente.

Para o treinamento e testes do classificador, os autores utilizaram o mesmo grupo de imagens, devido ao número limitado de casos disponíveis. O grupo

é composto por 51 calcificações, previamente classificadas por exame de biópsia, das quais 28 eram de lesões benignas e 23 de lesões malignas.

O sistema desenvolvido por William G. Wee *et al.*, apresentou 88.2% de acerto, classificando corretamente 23 calcificações malignas e 22 calcificações benignas. De acordo com os autores, se apenas três atributos forem utilizados para a classificação, o grupo de atributos, comprimento horizontal aproximado, nível de cinza médio dos pixels internos à calcificação e contraste, apresenta 84.3% de acerto, com 22 casos benignos e 23 malignos classificados corretamente.

Segundo um artigo publicado em 1993 por J. Parker, D. R. Dance, D. H. Davies, L.J.Yeoman, M.J.Michell e S.Humphreys [PARKER-93], o carcinoma *ductal in situ* (CDI) representa cerca de 20% dos cânceres detectados através da mamografia. O CDI é uma lesão de mama caracterizada pelo desenvolvimento do tumor no interior dos ductos de leite da mama. Aproximadamente 70 a 80% desse tipo de carcinoma apresentam calcificações associadas e, segundo os autores, existem tipos malignos (*comedo carcinoma ductal in situ*) e benignos (*não-comedo carcinoma ductal in situ*) de CDI, cuja classificação pode ser efetuada com base nas características das calcificações associadas.

Calcificações de CDI possuem diferentes características mamográficas, dependendo de sua categoria. Calcificações associadas a *comedo* CDI são tipicamente lineares e ramificadas ao contrário das associadas a *não-comedo* CDI que são arredondadas ou em forma de pontos. Este fenômeno é devido ao padrão de crescimento das células do tumor no interior dos ductos da mama. Segundo J. Parker *et al.*, existem casos em que *comedo* carcinomas apresentam características benignas, sendo estes casos atípicos e de difícil diagnóstico (possíveis falso-negativos).

Neste trabalho, os autores implementam métodos de análise de imagens para classificar automaticamente casos de CDI em duas classes: *comedo* carcinoma e *não-comedo* carcinoma. O estágio de classificação possui duas etapas: na primeira as microcalcificações são classificadas individualmente dentro da imagem e na segunda a própria imagem é classificada.

Para a implementação e testes do classificador, foram utilizados 20 casos de CDI apresentando calcificações nos mamogramas, sendo cada caso previamente classificado por um especialista. Dos 20 casos citados, 4 são

mamogramas típicos de *não-comedo*, 6 são casos atípicos de *comedo* e 10 são casos típicos de *comedo*.

As microcalcificações foram segmentadas manualmente e de cada uma foram extraídos os atributos descritos na tabela 2.3. Os atributos de forma, excentricidade e direcionalidade, são medidas da linearidade das microcalcificações. Área, diferença de níveis de cinza, contraste, entropia e variância foram escolhidos para refletir as diferenças radiométricas entre as microcalcificações. Excentricidade e "fullness" avaliaram a quantidade de microcalcificações ramificadas. Todos os atributos foram normalizados para terem média zero e desvio padrão igual a um, e como medida de similaridade foi escolhida a distância Euclidiana.

Um algoritmo de seleção de atributos, utilizando técnica de agregamento ("clustering"), foi desenvolvido para analisar o melhor subgrupo a ser usado no primeiro estágio da classificação. Os atributos escolhidos foram; grau de compactação e direcionalidade, os quais proporcionaram a menor sobreposição entre os espaços de atributos das duas classes, medida através do erro Bayesiano.

Após a extração e seleção dos atributos, cada microcalcificação foi classificada individualmente na imagem, através do método estatístico não-paramétrico K-NN, que pode operar sobre grupos de dados esparsos. Por ser uma técnica supervisionada, J. Parker *et al* fizeram uso de todas as informações *a priori* conseguidas de patologias verdadeiras.

Para a classificação da imagem os autores utilizaram um "threshold" T (equação 2-1) sobre o resultado da classificação das microcalcificações.

$$T = non\_max + \frac{1}{5}(com\_min - non\_max) \quad (2-1)$$

onde,

*non\_max* = maior fração de microcalcificações malignas (*comedo*) encontradas em casos típicos *não-comedo* da amostra de treinamento.

*com\_min* = menor fração de microcalcificações malignas (*comedo*) encontradas em casos típicos *comedo* da amostra de treinamento.

Dos casos típicos (*comedo* e *não-comedo*) utilizados para teste do classificador, apenas um foi classificado incorretamente como *não-comedo*, mas com baixo grau de confiança. Dos 6 casos de *comedo* atípicos, 2 foram classificados

corretamente e 4 foram classificados incorretamente como *comedos*. Segundo os autores, os atributos utilizados não foram suficientes para separar as duas classes.

Nome do Atributo	Descrição	Medida de:
Área	Número de pixels no objeto	contraste
“foreground”	Nível de cinza médio dos pixels do objeto	contraste
“background”	Nível de cinza médio dos pixels 8-conectados da borda do objeto	contraste
Diferença	“foreground” - “background”	contraste
Contraste	Diferença ÷ (“foreground” + “background”)	contraste
Grau de compactação	$(\text{perímetro})^2 \div 4\pi(\text{área})$	forma
Entropia	Entropia dos níveis de cinza dos pixels do objeto	textura
Excentricidade	$r_{\max} \div r_{\min}$	forma
Orientação	Definida pelo vetor de maior raio	forma
Direção	Definida pelo maior eixo do menor retângulo contendo a microcalcificação	forma
Variância	Variância do nível de cinza dos pixels do objeto	textura
Direcionalidade	Max (dimensões do retângulo de borda) ÷ Min (dimensões do retângulo de borda)	forma
“fullness”	(área do objeto) ÷ (área do retângulo de borda)	forma
$r_{\min}$	- distância entre o centro de massa e o pixel de borda mais próximo	
$r_{\max}$	- distância entre o centro de massa e o pixel de borda mais distante	

Tabela 2.3 - Atributos utilizados na classificação de microcalcificações - [PARKER-93].

A partir da análise dos mamogramas e dos valores dos atributos extraídos, constatou-se que os casos atípicos de *comedo* apresentaram um pequeno número (14 a 38) de microcalcificações, indicando um estágio precoce de desenvolvimento do tumor. De acordo com J.Parker *et al.* o aparecimento de características evidentes de *comedo* carcinoma depende do grau de desenvolvimento desse tipo de lesão. Isso explica a grande sobreposição entre os espaços de atributos morfológicos das classes benigna e maligna de CDI. Outra observação diz respeito aos níveis de cinza médios das calcificações e estruturas de fundo, variando de 141 a 190 para *comedos* atípicos e 195 a 212 para casos típicos de *não-comedo*. Também constatou-se uma diferença de contraste entre os dois casos, possuindo os *comedos* atípicos um maior contraste.



Em 1994, os mesmos autores publicaram em [PARKER-94], um artigo acrescentando inovações ao trabalho de 1993 [PARKER-93]. Dentre as inovações estão a elaboração de novos atributos e a apresentação dos resultados através de curvas ROC. Os novos atributos implementados são relacionados na tabela 2.4. Para determinar os atributos mais correlacionados, foi utilizado o coeficiente de correlação momento-produto,  $r$ , ( $|r| \leq 1$ ) calculado entre os pares de atributos analisados. Dois pares de atributos se apresentaram altamente correlacionados: “foreground” e “background” ( $r=0.99$ ) e contraste e diferença ( $r=0.98$ ). Os atributos “foreground” e contraste foram excluídos do grupo de atributos. Para a classificação, os autores utilizaram o método K-NN.

Um grupo de 32 casos foi dividido em dois subgrupos, onde o primeiro foi utilizado para treinar o classificador e o outro para otimizar o seu desempenho. O primeiro grupo consistiu de 6 casos, analisados por um especialista, sendo apenas 3 destes de *comedo* carcinoma. Os 6 casos foram utilizados para dar origem ao espaço de atributos necessário ao treinamento do método K-NN. O segundo grupo, contendo 26 casos (6 *não-comedo* e 20 *comedo* carcinomas) foi utilizado para testar o desempenho do classificador.

Nome do Atributo	Descrição	Medida de:
“edge-strength”	Gradiente médio em nível de cinza da borda do objeto	Contraste
Excentricidade <sub>2</sub>	$A \div B$	Forma
Excentricidade <sub>3</sub>	$I_{max} + I_{min}$	Forma
Raio de giro	Sobre o centro de massa	Textura
$\phi_1$	Momento invariante de Hu	Forma
$\phi_2$	Momento invariante de Hu	Forma
Par	Direcionalidade do objeto	Forma
Comio	indica se o centro de massa está dentro ou fora do objeto	Forma
A, B	- semi-eixo da menor elipse circunscrita à microcalcificação	
$I_{max}$ , $I_{min}$	- momentos de inércia sobre A e B	
$r_{min}$	- distância entre o centro de massa e o pixel de borda mais próximo	
$r_{max}$	- distância entre o centro de massa e o pixel de borda mais distante	

Tabela 2.4 - Novos atributos utilizados na classificação de microcalcificações - [PARKER-94]

Os autores mantiveram a mesma metodologia utilizada em [PARKER-93], para a classificação das microcalcificações e das imagens, com exceção que nenhum caso de *comedo* atípico foi analisado. O desempenho do classificador foi medido através de curvas ROC para várias combinações de atributos, conforme indicado na tabela 2.5.

Área sob a curva ROC	Atributos utilizados (combinados)
0.80	Diferença, entropia, excentricidade <sub>1</sub> , excentricidade <sub>2</sub> , $\phi_1$
0.80	entropia, excentricidade <sub>1</sub> , excentricidade <sub>2</sub> , $\phi_1$ , $\phi_2$
0.79	Entropia, variância, excentricidade <sub>2</sub> , $\phi_1$
0.79	entropia, excentricidade <sub>1</sub> , variância, excentricidade <sub>2</sub> , $\phi_1$
0.78	Excentricidade <sub>1</sub> , excentricidade <sub>3</sub> , $\phi_2$ , par, comio

Tabela 2.5 - Resultados da classificação de *comedo* carcinomas, utilizando-se várias combinações de atributos - [PARKER-94]

Em um trabalho escrito em 1992 e publicado em 1994, L. Shen, R.M. Rangayyan e J.E.L. Desautels [SHEN-94], desenvolveram um grupo de fatores de forma para medir o nível de rugosidade de contornos de calcificações presentes em mamogramas. Esses fatores são utilizados para a classificação das calcificações em dois grupos: benignas e malignas.

Neste trabalho, a análise do mamograma é executada em 3 estágios. Primeiro, a técnica de crescimento de região é utilizada para obter o contorno dos sinais. O algoritmo de crescimento de região inicia-se com a seleção manual de uma semente e um valor de tolerância  $\tau$  ( $0 \leq \tau \leq 1$ ) escolhido de acordo com as características da imagem. O valor do pixel  $p(i,j)$ , de cada vizinho 4-conectado pertencente a região, é examinado para a seguinte condição:

$$(1+\tau)(F_{\max}+F_{\min})/2 \geq p(i,j) \geq (F_{\max}+F_{\min})/2$$

onde  $F_{\max}$  e  $F_{\min}$  são os valores dos pixels máximo e mínimo, respectivamente, da região analisada. Se a condição é satisfeita o pixel é incluído na região. Esse procedimento é recursivo e continua até que nenhum dos pixels 4-conectados satisfaçam a condição acima. A camada mais externa dos pixels conectados é então tratada como contorno da região.

No segundo estágio, para cada região são calculadas três medidas de forma: grau de compactação (C), momentos da região de borda ( $F_3'$ -  $F_1'$ ) e descritores de Fourier (FF) (capítulo 3, seções 3.1.4, 3.1.2 e 3.1.3, respectivamente). Nesse estágio, os autores utilizaram duas imagens de testes contendo diversas formas geométricas com orientações e escalas diferentes. A primeira, possuindo objetos bem definidos, foi utilizada para comparar os novos descritores  $F_1'$ ,  $F_2'$  e  $F_3'$  com os desenvolvidos por L.Gupta e M.D.Srinath [GUPTA-87]. A segunda imagem, contendo objetos não tão bem definidos, foi usada na avaliação dos descritores C, ( $F_3'$ -  $F_1'$ ) e FF utilizados pelo classificador.

Finalmente, na terceira e última etapa, o grupo utiliza a técnica K-NN para a classificação das calcificações. Como medida de similaridade para a técnica K-NN, é utilizada a distância Euclidiana normalizada.

Na avaliação do classificador, os autores usaram 18 mamogramas com os resultados das biópsias associados. Desses 18 casos, 64 calcificações benignas (de 11 mamogramas) e 79 calcificações malignas (de 7 mamogramas) foram manualmente escolhidas. Tanto calcificações isoladas como agrupamentos de calcificações foram incluídos nos dois grupos.

Utilizando as três medidas de forma, a técnica proposta atinge 100% de acerto na classificação tanto de calcificações malignas quanto benignas. Os autores também apresentam a tabela 2.6, comparando o uso isolado ou combinado (dois a dois) dos atributos e a taxa de acerto na classificação.

Fatores de Forma	Classificação correta para calcificações benignas (nro.calcificações =64)	Classificação correta para calcificações malignas (nro.calcificações=79)
( $F_3'$ - $F_1'$ ) FF C	64 (100%)	79 (100%)
( $F_3'$ - $F_1'$ ) FF	55 (85,94%)	70 (88,61%)
( $F_3'$ - $F_1'$ ) C	63 (98,44%)	78 (98,73%)
FF C	60 (78,12%)	76 (98,73%)
( $F_3'$ - $F_1'$ )	50 (78,12%)	62 (78,48%)
FF	54 (84,38%)	67 (84,81%)
C	62 (96,88%)	77 (97,47%)

Tabela 2.6 - Resultados da classificação de 143 calcificações para diferentes combinações dos fatores de forma propostos - [SHEN-94]

Em 1995, Ulisses de Mendonça Braga Neto e Winston Araújo de Siqueira Neto [NETO-95], publicaram uma técnica para detecção e classificação automática de calcificações mamográficas. Para a extração das calcificações, os autores utilizaram o método “Watershed”, que aplica morfologia matemática para realizar a segmentação de imagens, com as sementes escolhidas manualmente dentro de cada calcificação visível.

Após a segmentação de cada calcificação, foram extraídos os atributos de forma; grau de compactação e primeiro momento invariante. Como classificador, os autores utilizaram o método K-NN. Um total de 74 calcificações, sendo 21 benignas e 53 malignas, foram utilizadas no treinamento e testes do algoritmo implementado. Para estimar a probabilidade de erro do classificador, utilizou-se o método “leave-one-out”. Este método consiste em, dado um conjunto de amostras para teste, no caso as imagens dos mamogramas, separa-se uma única amostra do espaço amostral (dimensão  $d$ ) e então efetua-se a classificação no espaço amostral restante (dimensão  $d-1$ ). Este procedimento é repetido para cada uma das amostras e depois compara-se os resultados obtidos. De acordo com o método “leave-one-out”, o classificador mostrou, segundo os autores, uma eficiência de 90,48% para tumores benignos, 98,11% para tumores malignos e 95,95% para a classificação global.

## 2.2.4 – Classificação através de Redes Neurais Artificiais

Em 1993, Liang Shen e Rangaraj M. Rangayyan [SHEN-93A], [SHEN-93B] propuseram um novo sistema para detecção e classificação de calcificações mamográficas. Primeiro foi proposto um método de crescimento de região multi-tolerância para a detecção de supostas regiões de sinais e extração de seus contornos. Para vários valores de tolerância, o método aplica a distância métrica calculada entre os grupos de atributos, incluindo forma, centro de gravidade e tamanho, para determinar os melhores parâmetros. Então são extraídas informações de forma, a partir de descritores de momentos, descritores de Fourier e solidez, com base nos contornos das regiões. Finalmente, os autores utilizaram uma rede neural artificial do tipo “perceptron” com duas camadas, sendo uma escondida, e função de



ativação do tipo “sigmoid” binário, para realizar a classificação. Como entrada para a rede neural, são utilizados os fatores de forma obtidos na etapa anterior, e como saída é fornecida a classificação das calcificações em benignas ou malignas.

O treinamento da rede foi realizado a partir dos mesmos 18 mamogramas, com comprovação por biópsia, utilizados em [SHEN-94]. Estes mamogramas continham um total de 64 calcificações benignas e 79 malignas. Para o teste de detecção e classificação, [SHEN-93] utiliza um conjunto de quatro mamogramas de imagens completas contendo 58 calcificações benignas e outro contendo  $241 \pm 10$  calcificações malignas. Baseado na inspeção visual feita por um radiologista, o algoritmo de crescimento de região teve uma taxa de detecção de 81% com 0% de taxa de falsa detecção para as calcificações benignas e  $85 \pm 3\%$  com 29 falsas detecções para as malignas. A taxa de acerto obtida na classificação pela RNA foi de 94% de acerto para as benignas e 87% para as malignas. Embora o resultado seja inferior ao obtido no artigo anterior ( [SHEN-94] ), este novo método possui a vantagem de descartar um método de segmentação interativo.

Em um artigo publicado em 1996, Yulei Jiang, Robert M. Nishikawa, Dulcy E. Wolverton, Charles E. Metz, Maryellen L. Giger, Robert A. Schmidt, Carl J. Vyborny e Kunio Doi [JIANG-96] desenvolveram um método para diferenciar microcalcificações malignas e benignas contidas em agrupamentos. O método é composto por duas etapas: a primeira extrai informações de forma das microcalcificações previamente marcadas por um especialista e a segunda efetua a classificação das microcalcificações através de uma rede neural artificial.

Na etapa de extração de atributos, os autores desenvolveram 12 índices de forma para caracterizar as irregularidades das microcalcificações. Quatro destes índices representam as distâncias entre o pixel localizado no centro de massa da microcalcificação e as bordas do menor retângulo contendo a microcalcificação. Os outros oito índices, são formados pelas máximas distâncias entre o pixel do centro de massa e os pixels da microcalcificação, localizados a  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$ ,  $180^\circ$ ,  $225^\circ$ ,  $270^\circ$  e  $315^\circ$ . O desvio padrão calculado a partir dos 12 índices foi usado para identificar microcalcificações lineares ou irregulares, sugerindo uma medida de malignidade. Segundo os autores, essa medida realmente caracteriza o formato das microcalcificações, pois para uma microcalcificação compacta, todos os 12 índices

terão valores próximos e portanto, seu desvio padrão será baixo. Para uma microcalcificação com formato irregular, alguns índices terão valores altos e outros baixos, e dessa forma o valor do desvio padrão será grande. Yulei Jiang *et al* também utilizaram a margem estimada do agrupamento das microcalcificações para calcular o grau de compactação do agrupamento, dado por  $4\pi A / P^2$ , onde  $A$  é a área do agrupamento e  $P$  o seu perímetro.

Para a classificação, os autores utilizaram uma RNA “feedforward” de três camadas, treinada pelo algoritmo “backpropagation”. A RNA possui oito unidades de entrada, uma camada escondida e uma unidade na saída. As unidades de entrada correspondem a oito atributos selecionados, extraídos das microcalcificações e do agrupamento. Os valores numéricos de cada atributo foram normalizados entre 0 e 1 de acordo com o máximo valor encontrado no grupo de atributos. A unidade de saída da rede fornece saídas entre 0 e 1, indicando a o tipo de suspeita (0 = benigno, 1= maligno). De acordo com Yulei Jiang *et al.*, a curva ROC comparativa, obtida através dos resultados do método proposto e da classificação realizada por especialistas, apresenta um área de 0.92 para o método proposto e 0.89 por inspeção dos especialistas. De acordo com os autores, o desempenho do método pode ser melhorado, aumentando-se o número de casos utilizados no treinamento da RNA.

## **2.3 - Classificação de agrupamentos de microcalcificações**

Na classificação de agrupamentos de microcalcificações, os pesquisadores geralmente analisam informações de textura, distribuição espacial das microcalcificações dentro do agrupamento, distribuição interpartícula, forma e tamanho do agrupamento, etc. O objetivo é determinar, a partir dessas características, se o agrupamento é associado a uma lesão de mama maligna ou benigna.

### **2.3.1 – Classificação através de Redes Neurais Artificiais**

No ano de 1994, Yulei Jiang, Robert M. Nishikawa, Dulcy E. Wolverton, Maryellen L. Giger, Kunio Doi, Robert A. Schmidt e Carl J. Vyborny [JIANG-94], publicaram um artigo descrevendo o uso de atributos extraídos de agrupamentos de microcalcificações para a classificação de lesões de mama em benigna ou maligna. O método é composto por duas fases: extração de atributos e classificação.

Na fase de extração, os autores utilizaram os seguintes atributos: área e circularidade do agrupamento, número de microcalcificações por agrupamento e por unidade de área, distância média entre as microcalcificações, área média e volume efetivo das microcalcificações e uma medida de irregularidade de cada microcalcificação dentro do agrupamento. As microcalcificações foram segmentadas por crescimento de região, depois da imagem ter sido filtrada para a eliminação de componentes de fundo.

Para a classificação, foi utilizada uma RNA “feedforward” de três camadas e treinada pelo algoritmo “backpropagation”, com 8 unidades na camada de entrada, 6 unidades na camada escondida e 1 unidade na camada de saída.

Os resultados da classificação, em termos de agrupamentos e de malignidade associada ao paciente, foram analisados separadamente. A classificação de agrupamentos foi obtida através da escolha de um valor de “threshold” apropriado para a saída numérica da RNA. A área sob a curva ROC para a classificação de agrupamentos de microcalcificações foi de 0.83, sendo classificados corretamente 38 dos 40 agrupamentos malignos e 34 dos 67 agrupamentos benignos.

Para a classificação da lesão, relacionada ao paciente, foi utilizado o maior valor numérico da classificação de todos os agrupamentos associados a ele. Todos os 19 casos de pacientes com câncer e 24 dos 34 pacientes com lesões benignas foram corretamente classificados, resultando em uma área sob a curva ROC igual a 0.92.

Também em 1994, Yateen Chitre, Atam P. Dhawan e Myron Moskowitz [CHITRE-94] implementaram vários métodos para a classificação de agrupamentos de microcalcificações mamárias, a partir de informações estruturais da imagem. De acordo com Yateen Chitre *et al.*, muitas das técnicas utilizadas para a

análise de microcalcificações mamográficas, segmentam a imagem em regiões representando as microcalcificações. O processo de segmentação quase sempre deforma a verdadeira forma das microcalcificações, devido ao baixo contraste das estruturas da imagem. Por esse motivo os autores utilizaram neste trabalho atributos extraídos do histograma de níveis de cinza de segunda-ordem,  $p(i,j)$ , (ou matriz de co-ocorrência), e do histograma de segunda-ordem da diferença,  $p_{x-y}(k)$  (capítulo 3, seção 3.2), os quais não requerem a etapa de segmentação.

A partir de  $p(i,j)$  são extraídos os valores de entropia, contraste, segundo momento angular, momento da diferença inversa e correlação. De  $p_x(i)$  e  $p_y(j)$ , que são as distribuições marginais unidimensional de  $p(i,j)$ , são extraídos a média e o desvio padrão. Por fim, de  $p_{x-y}(k)$  são calculados a entropia, segundo momento angular e a média.

Todos os atributos foram obtidos para um grupo de 95 imagens mamográficas com resultados de biópsia, sendo 57 casos de microcalcificações associadas a tumores malignos e 38 a tumores benignos. Depois da digitalização, todos os mamogramas foram analisados para a extração de ROIs contendo áreas com microcalcificações.

Para cada atributo calculou-se os valores da média e variância das funções densidades de probabilidade (pdf) gaussianas das classes benignas e malignas. A eficácia desses atributos foi estudada com base nas regiões sobrepostas das curvas pdf, que dão a Probabilidade de Erro da Classificação (PEC).

Após a seleção dos melhores atributos, através do PEC, os mesmos foram calculados para 4 diferentes valores de distância  $d$ : 1,4,7 e 10. Uma análise multivariada baseada na covariância foi efetuada para analisar a correlação entre os atributos, quando calculados para diferentes distâncias. A análise de correlação foi realizada, para cada par de atributos combinados, através do coeficiente de correlação  $r_{i,k}$  (equação 2-2). Os pares de atributos com valores de  $r_{i,k}$  próximos de 1 foram eliminados.

$$r_{j,k} = \frac{\sum_i (x_{i,j} - \bar{x}_j)(x_{i,k} - \bar{x}_k)}{\sqrt{\sum_i (x_{i,j} - \bar{x}_j)^2} \sqrt{\sum_i (x_{i,k} - \bar{x}_k)^2}} \quad (2-2)$$



$$\text{onde } \bar{x}_j = \frac{1}{N} \sum_i x_{i,j} \text{ e} \quad (2-3)$$

$$\bar{x}_k = \frac{1}{N} \sum_i x_{i,k} \quad (2-4)$$

A seguir, os autores aplicaram a técnica de agregamento de dados “K-Médias” (“K-Means Clustering”) para os 10 atributos extraídos das 95 imagens. Todos os atributos foram organizados, independentemente, em 2, 3, 4, 5, 6 e 7 agrupamentos, a partir da seguinte medida de desempenho:

$$f(k, x_1, x_2, \dots, x_n) = \sum_{i=1}^k \sum_{j=1}^k r_{ij} m_i m_j \quad (2-5)$$

onde  $k$  é o número de agrupamentos,  $x_1, x_2, \dots, x_n$  é a combinação de  $n$  atributos,  $r_{ij}$  é a distância Euclidiana entre os  $i$ -ésimo e  $j$ -ésimo centros dos agrupamentos e  $m_i$  é dado por:

$$m_i = \left( \frac{n_{ib}}{n_i} - 0.5 \right)^2 n_i \quad (2-6)$$

Os casos onde a medida de desempenho foi baixa foram desprezados, e dos que permaneceram, os autores observaram os atributos com maior ocorrência. Dessa forma com base na PEC e no método “K-Médias”, os autores selecionaram dois principais grupos de atributos. O primeiro foi composto por contraste, segundo momento, desvio padrão, segundo momento angular de  $p_{x-y}(k)$  e entropia de  $p_{x-y}(k)$ , e o segundo por desvio padrão, entropia de  $p_{x-y}(k)$ , contraste e segundo momento angular.

Para a classificação, foram implementadas quatro redes neurais artificiais “feedforward”, com diferentes combinações dos casos de treinamento e testes e do número de nós da camada escondida. As taxas de falso-positivo e verdadeiro-positivo, para a classificação das microcalcificações, foram calculadas para comparar o desempenho das RNAs treinadas.

O desempenho da classificação utilizando as RNAs foi comparado aos resultados dos classificadores paramétricos Bayesianos (linear e quadrático) e ao classificador não-paramétrico K-NN. Para os dois últimos classificadores, os autores utilizaram duas diferentes combinações de amostras de treinamento, uma com 5 e outra com 15 casos. Os custos do erro de classificação e as probabilidades *a priori*

dos classificadores paramétricos foram assumidas iguais para ambas as classes. De acordo com os autores, as redes neurais apresentaram resultados superiores aos demais métodos, chegando a uma taxa de verdadeiro-positivo de 91%, seguido pelo método K-NN com 72.4%. No entanto, a taxa de falso-positivo para o melhor resultado das redes neurais foi muito elevado: 83%. A menor taxa de falso-positivos foi de 35%, conseguida também por uma rede neural, mas com uma taxa de verdadeiro-positivo de 73%.

Uma pesquisa utilizando atributos de textura, extraídos de ROIs, para a classificação de agrupamentos de microcalcificações foi apresentada em 1997 por Heang-Ping Chan, Berkman Sahiner, Nicholas Petrick, Mark A. Helvie, Kwok Leung Lam, Dorit D. Adler e Mitchell M. Goodsitt [CHAN-97].

Neste trabalho, os autores utilizaram 86 mamogramas, contendo agrupamentos de microcalcificações, obtidos de 54 casos (26 benignos e 28 malignos). Dos 86 mamogramas utilizados, 41 apresentavam agrupamentos malignos e 45 benignos, confirmados por biópsia. Os agrupamentos foram organizados de acordo com o nível de dificuldade encontrado no diagnóstico realizado por especialistas (1=óbvios; 5=muito sutis).

Neste trabalho, a localização dos agrupamentos de microcalcificações em cada mamograma foi realizada por especialistas, de maneira que apenas os agrupamentos fossem analisados. Regiões de interesse de 1024x1024 pixels (correspondendo a 3,58 cm x 3,58 cm no mamograma) na imagem, com o agrupamento aproximadamente no centro, foram extraídas dos mamogramas. A seguir aplicou-se, a cada ROI, uma técnica para a correção do fundo da imagem, antes da extração dos atributos de textura.

A matriz de co-ocorrência de níveis de cinza foi calculada sobre cada uma das ROIs separadas dos mamogramas e a partir dela foram calculados os seguintes atributos: energia, correlação, inércia, entropia, momento da diferença inversa, média da soma dos níveis de cinza, variância e entropia da média da soma dos níveis de cinza, média da diferença entre níveis de cinza, variância e entropia da média da diferença entre os níveis de cinza e uma medida de correlação. Para a seleção dos atributos mais representativos e discriminatórios das classes benigna e maligna, os autores utilizaram o método "stepwise". Na etapa de seleção os autores

separam, a partir da variação dos parâmetros  $F_{in}$  e  $F_{out}$  do método “stepwise”, quatro grupos de atributos para serem utilizados na classificação.

O classificador proposto é formado por uma RNA “feedforward” de três camadas, sendo uma escondida, e treinado pelo algoritmo “backpropagation”. O método “leave-one-out” foi utilizado para testar o desempenho da rede.

O melhor resultado da classificação foi conseguido para um grupo de seis atributos, resultando numa área sob a curva ROC de 0.88. Segundo os autores, os resultados preliminares do trabalho de classificação de microcalcificações, indicam que o uso de atributos de textura pode revelar informações que não estão aparentes numa inspeção visual.

### **2.3.2 - Classificação de lesões de mama através de informações fornecidas por especialistas**

No ano de 1993, Yuzheng Wu, Maryellen L. Giger, Kunio Doi, Carl J. Vyborny, Robert A. Schmidt e Charles E. Metz [WU-93], implementaram um rede neural artificial para a classificação de lesões de mama, a partir de informações extraídas por especialistas dos mamogramas.

Um total de 43 atributos foram selecionados para a entrada da RNA. Esses atributos foram divididos em três grupos: atributos relacionados a massas (forma, tamanho, borda, irregularidades), atributos relacionados às microcalcificações (número, forma, uniformidade, distribuição) e atributos secundários (distorção do parênquima da mama, rugosidade da pele).

Como classificador, os autores utilizaram uma RNA “feedforward” com três camadas sendo uma escondida e treinada pelo algoritmo “backpropagation”. Para o treinamento e análise de desempenho da RNA os autores utilizaram 133 imagens extraídas de um livro didático e 60 casos clínicos, respectivamente. No treinamento da RNA, foi utilizado o método “leave-one-out” sobre o grupo de treinamento, sendo obtida uma área de 0.95 sob a curva ROC. Também para efeito de comparação entre os resultados da classificação obtidos pela RNA, 10 radiologistas (5 experientes e 5 residentes) foram acompanhados na classificação dos

60 casos clínicos. De acordo com os resultados das curvas ROC, a rede neural apresentou uma área sob a curva ROC de 0.89 contra 0.85 de um especialista que analisou sozinho as imagens.

# Capítulo 3

## Principais atributos utilizados na classificação de lesões de mama

Como visto no capítulo 2, seções 2.2 e 2.3, o número de medidas realizadas sobre as microcalcificações isoladas ou agrupadas, descritas na literatura, é extremamente grande. Neste capítulo, serão descritas as principais medidas (atributos) citadas nos trabalhos, sendo divididas em dois grupos: atributos extraídos de microcalcificações isoladas (individuais) e atributos extraídos de agrupamentos de microcalcificações.

### 3.1 - Atributos extraídos de microcalcificações isoladas

De acordo com Liang Shen *et al* [SHEN-94], a forma das microcalcificações é um dos critérios mais importantes na distinção entre lesões de mama benignas e malignas. Dessa maneira vários estudos têm se concentrado na análise da forma das microcalcificações. Em um artigo publicado em 1975, W.G. Wee *et al.* [WEE-75] usaram o desvio padrão da distância entre os pontos de borda e o centróide da região da calcificação como um fator de forma. Esta medida entretanto não pode descrever a rugosidade exata das formas. Em 1979, W.Spiesberger [SPIESBERGER-79] fez uso de um tipo de medida de solidez para caracterizar as calcificações compactas das perfuradas. Utilizando também medida de solidez, D.H.Davies e D.R. Dance [DAVIES-90] diferenciaram calcificações de estruturas normais da mama. Em 1989, I.E.Magnin *et al.* [MAGNIN-89], publicaram um artigo sobre a classificação de microcalcificações mamárias utilizando métodos de análise de forma baseados no perímetro, área, solidez, excentricidade, coeficiente

de convexidade, razão de comprimento e raio médio. Entretanto, suas medidas, exceto solidez, não caracterizam diretamente a rugosidade das formas das microcalcificações.

Em um artigo publicado em 1994, Liang Shen *et al.* [SHEN-94] descrevem um grupo de fatores de forma, por eles desenvolvidos, para a medida de rugosidade do contorno das calcificações. O grupo de medidas é composto por: momentos de borda das microcalcificações, descritores de Fourier e solidez.

### 3.1.1 - Momentos regulares

Segundo Arun D. Kulkarni [KULKARNI-94] e [SHEN-94], momentos têm sido utilizados como atributos de padrões em um grande número de aplicações, sendo os momentos regulares o tipo mais comum. Dada uma imagem  $f(x,y)$  de tamanho  $N_x \times N_y$ . O momento geométrico de ordem  $(p+q)$  é dado por:

$$m_{pq} = \sum_{x=1}^{N_x} \sum_{y=1}^{N_y} x^p y^q f(x,y) \quad \text{para } p,q = 0,1,2,\dots \quad (3-1)$$

Para fazer esses momentos invariantes a translação, define-se o momento central como:

$$m_{pq} = \sum_{x=1}^{N_x} \sum_{y=1}^{N_y} (x - x')^p (y - y')^q f(x,y) \quad \text{onde } x' = \frac{m_{10}}{m_{00}} \quad \text{e} \quad y' = \frac{m_{01}}{m_{00}} \quad (3-2)$$

O momento central pode ser normalizado para ser invariante à escala como mostrado a seguir:

$$\mu_{pq} = \frac{m_{pq}}{m^{\gamma}_{00}} \quad \text{onde } \gamma = (p+q)/2 + 1 \quad (3-3)$$

Em 1992, M.K.Hu [HU-62] definiu um grupo de sete funções utilizando momentos centrais e que são invariantes à translação, escala e rotação do padrão de entrada. A principal desvantagem dessa técnica é que ela por si só não garante um grupo completo de descritores, entretanto para muitas aplicações o grupo de sete invariantes é adequado para a distinção entre padrões. O grupo de descritores de M. K. Hu são definidos por:

$$\phi_1 = (\mu_{20} + \mu_{02}) \quad (3-4)$$

$$\phi_2 = (\mu_{20} - \mu_{02})^2 + 4 \cdot \mu_{11}^2 \quad (3-5)$$

$$\phi_3 = (\mu_{30} - 3 \cdot \mu_{12})^2 + (3 \cdot \mu_{21} + \mu_{03})^2 \quad (3-6)$$

$$\phi_4 = (\mu_{30} + \mu_{12})^2 + (\mu_{21} + \mu_{03})^2 \quad (3-7)$$

$$\phi_5 = (\mu_{30} - 3 \cdot \mu_{12}) \cdot (\mu_{30} + \mu_{12}) \cdot [ (\mu_{30} + \mu_{12})^2 - (3 \cdot \mu_{21} + \mu_{03})^2 ] + \\ (3 \cdot \mu_{21} + \mu_{03}) \cdot (\mu_{21} + \mu_{03}) \cdot [ 3 \cdot (\mu_{30} + \mu_{12})^2 - (\mu_{12} + \mu_{03})^2 ] \quad (3-8)$$

$$\phi_6 = (\mu_{20} - \mu_{02}) \cdot [ (\mu_{21} + \mu_{03})^2 \cdot [ (\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2 ] + \\ 4 \cdot \mu_{11} \cdot (\mu_{30} + \mu_{12}) \cdot (\mu_{21} + \mu_{03}) \quad (3-9)$$

$$\phi_7 = (3 \cdot \mu_{21} - \mu_{03}) \cdot (\mu_{30} + \mu_{12}) \cdot [ (\mu_{30} + \mu_{12})^2 - 3 \cdot (\mu_{21} + \mu_{03})^2 ] - \\ (\mu_{30} - 3 \cdot \mu_{12}) \cdot (\mu_{12} + \mu_{03}) \cdot [ (3 \cdot \mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2 ] \quad (3-10)$$

Em 1994, J.Parker *et al.* [PARKER-94], utilizaram em seu trabalho, junto com outros atributos, os momentos  $\phi_1$  e  $\phi_2$ . Segundo os autores, os outros cinco momentos não foram utilizados pois os seus resultados foram zero para as imagens de treinamento, não tendo potencial discriminatório. Também em 1995, [NETO-95] classificou microcalcificações utilizando o primeiro momento de Hu ( $\phi_1$ ).

### 3.1.2 - Momentos de borda de região

Uma definição alternativa de momentos é usada em [SHEN-94] para uma seqüência de pixels de bordas. Por esta definição, momentos estatísticos unidimensionais são extraídos de uma representação sequencial da borda da região ou do objeto. A borda é caracterizada por uma seqüência ordenada que representa a distância Euclidiana entre o centróide da região e todos os pixels de contorno do objeto digitalizado. Esta seqüência ordenada é uma representação única da forma do objeto (assinatura do objeto).

Seja uma seqüência de N pixels do contorno de um objeto digitalizado sendo descrito por um grupo ordenado  $\{ x(i), y(i), i=1,2,\dots,N \}$ . As distâncias Euclidianas  $z(i), i=1,2,\dots,N$ , de cada vetor conectando o centróide  $(x', y')$  e o grupo de pixels de borda, formam uma representação funcional unidimensional, de valores simples do contorno. Dessa forma, o momento de ordem  $p$  é definido como:

$$m_p = \frac{1}{N} \sum_{i=1}^N [z(i)]^p \quad (3-11)$$

e o momento central de ordem  $p$  é dado por:

$$M_p = \frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^p \quad (3-12)$$

Os correspondentes momentos normalizados são:

$$\bar{m}_p = \frac{m_p}{(M_2)^{p/2}} = \frac{\frac{1}{N} \sum_{i=1}^N [z(i)]^p}{\left[ \frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^2 \right]^{p/2}} \quad (3-13)$$

e

$$\bar{M}_p = \frac{M_p}{(M_2)^{p/2}} = \frac{\frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^p}{\left[ \frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^2 \right]^{p/2}} \quad (3-14)$$

Os momentos  $\bar{m}_p$  e  $\bar{M}_p$ , segundo [GUPTA-87], são invariantes à translação, rotação e escala. Embora momentos de ordens arbitrárias possam ser derivados de seqüências de contornos e usados como características para a classificação de formas, devido a sua larga faixa dinâmica, momentos de alta ordem são mais sensíveis a ruído, e o classificador resultante será menos tolerante a ruído. Dessa forma, [GUPTA-87] selecionou 3 momentos de baixa ordem para formar um grupo de características de forma:

$$F_1 = \frac{(M_2)^{1/2}}{m_1} = \frac{\left[ \frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^2 \right]^{1/2}}{\frac{1}{N} \sum_{i=1}^N z(i)} \quad (3-15)$$

$$F_2 = \frac{M_3}{(M_2)^{3/2}} = \frac{\frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^3}{\left[ \frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^2 \right]^{3/2}} \quad (3-16)$$



$$F_3 = \frac{M_4}{(M_2)^2} = \frac{\frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^4}{\left[ \frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^2 \right]^2} \quad (3-17)$$

De acordo com os autores,  $F_1$  é uma medida da dispersão estatística que caracteriza a variabilidade da função densidade e também pode ser considerada como uma medida de variação da amplitude da seqüência de contorno. Essa medida é positiva, com um valor igual a zero apenas se o contorno for um círculo perfeito (a seqüência de contorno correspondente é constante sobre todo o seus pontos). As medidas de forma  $F_2$  e  $F_3$ , relacionam o grau de simetria e os picos da função densidade, respectivamente.  $F_2$  é positivo quando a maioria das amostras da seqüência do contorno possuir um valor menor que o valor médio da amostra e  $F_3$  é positivo se a maior parte da amostra concentrar-se ao redor da média.

Em 1994, L. Shen *et al.* [SHEN-94], utilizando os 3 fatores de forma  $F_1$ ,  $F_2$  e  $F_3$ , desenvolvidos por [GUPTA-87], realizaram um ensaio com uma imagem teste contendo várias formas geométricas com rotações e escalas diferentes. Os resultados desse ensaio mostraram que os descritores  $F_2$  e  $F_3$  variam muito pouco de uma categoria de forma para outra. Portanto os autores propuseram dois novos descritores,  $F_2'$  e  $F_3'$ , em substituição aos  $F_2$  e  $F_3$ .

$$F_2' = \frac{(M_3)^{1/3}}{m_1} = \frac{\left[ \frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^3 \right]^{1/3}}{\frac{1}{N} \sum_{i=1}^N z(i)} \quad (3-18)$$

$$F_3' = \frac{(M_4)^{1/4}}{m_1} = \frac{\left[ \frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^4 \right]^{1/4}}{\frac{1}{N} \sum_{i=1}^N z(i)} \quad (3-19)$$

Comparando com o grupo de atributos proposto em [GUPTA-87], este novo grupo, segundo os autores, possui as seguintes propriedades:

a) todos os atributos são adimensionais, permitindo comparações e combinações diretas.

b)  $F_3'$  descreve as irregularidades das formas melhor que  $F_3$ .

### 3.1.3 – Fator de forma a partir de Descritores de Fourier

Uma das mais promissoras técnicas para descrição de forma, segundo [SHEN-94], é baseada nos descritores de Fourier da borda de imagens. Supondo que  $N$  pontos estejam presentes nas bordas de uma região. Pode-se considerar a região como parte de um plano complexo, com a ordenada pertencente ao eixo imaginário e a abscissa pertencente ao eixo real. Então, as coordenadas x-y de cada ponto pertencente ao contorno analisado pode ser representado como um número complexo  $(x + jy)$ . A seqüência de borda pode então ser escrita como uma seqüência complexa  $Z_i = x_i + jy_i$ , com  $i=0,1,2,\dots,N-1$ .

A seqüência de números complexos é periódica através de cada borda completa. Os descritores de Fourier (DF) são definidos como:

$$A(n) = \frac{1}{N} \sum_{i=0}^{N-1} Z_i \exp(-j2\pi ni / N) \quad n=0,1,\dots,N-1 \quad (3-20)$$

como a transformada é inversível, então

$$Z_i = \sum_{n=0}^{N-1} A(n) \exp(j2\pi ni / N) \quad i=0,1,\dots,N-1 \quad (3-21)$$

Antes do uso de DFs para análises de forma, é preciso eliminar sua dependência com relação à posição, tamanho, orientação e ponto inicial do contorno. De acordo com R.C. Gonzales e P.Wintz [GONZALES-87], as propriedades mais importantes que devem ser levadas em consideração são:

- a) Mudanças na posição do contorno (translação) alteram apenas  $A(0)$ .
- b) Para efetuar mudanças na escala do contorno, os componentes dos DFs necessitam simplesmente ser multiplicados por uma constante (escalar).
- c) Para realizar uma rotação do contorno no domínio espacial, cada coordenada deve ser multiplicada por  $e^{j\theta}$ , onde  $\theta$  é o ângulo de rotação. Devido a linearidade da transformada de Fourier, multiplicando os coeficientes do domínio da freqüência por  $e^{j\theta}$  tem-se o mesmo efeito.

d) O deslocamento do ponto inicial do contorno no domínio espacial, corresponde à multiplicação do k-ésimo coeficiente no domínio da frequência por  $e^{jkT}$ , onde T é a fração do período através do qual o ponto inicial é deslocado.

No entanto, como Liang Shen *et al.* apenas utilizaram as amplitudes dos DFs, eles normalizaram os descritores ajustando o valor de  $A(0)$  para zero, fazendo-os independentes da posição, e dividiram cada coeficiente pela amplitude de  $A(1)$  para normalizar o tamanho.

A partir dos descritores de Fourier normalizados, os autores definiram o fator descrito na equação 3-22.

$$FF = \frac{\left[ \sum_{k=-N/2+1}^{N/2} \frac{\|DFN(k)\|}{|k|} \right]}{\sum_{k=-N/2+1}^{N/2} \|DFN(k)\|} \quad (3-22)$$

Na equação 3-22, a divisão por  $|k|$  enfatiza os componentes de baixa frequência. Portanto o valor de  $FF$  será pequeno se mais energia estiver distribuída na parte de alta frequência. De acordo com Liang Shen *et al.* a vantagem desse fator é que ele é insensível a ruídos de altas frequências e é limitado entre 0 e 1.

### 3.1.4 - Grau de compactação ( Solidez )

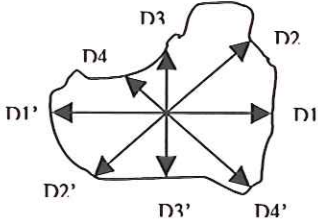
O grau de compactação ou solidez é, segundo [PARKER-93] e [NETO-95], uma medida simples de rugosidade e muito apropriada para caracterizar microcalcificações. Essa medida é definida como a razão entre o perímetro  $P$  ao quadrado e a área  $A$ , sendo adimensional e invariante à escala, translação e rotação.

$$C = \frac{P^2}{A} \quad \text{ou} \quad C = 1 - \frac{P^2}{A} \quad \text{fazendo com que o valor permaneça entre 0 e 1.}$$

Apesar de ser uma medida simples, diversos trabalhos, [MAGNIN-89], [PARKER-93], [PARKER-94], [SHEN-93A], [SHEN-93B] e [SHEN94], utilizam esse fator para a classificação. É fácil observar que para um objeto em forma de círculo o valor do grau de compactação é dado por  $C = \frac{(2\pi R)^2}{\pi R^2} = 4\pi$ . Portanto, alguns autores introduzem a constante  $4\pi$  à fórmula, de maneira que a medida “C” permaneça entre 0 e 1.

### 3.1.5 – Medidas de forma e suavidade

Dois formas para medir o grau de assimetria de microcalcificações foram propostas por I.E. Magnin *et al.* em 1989. A primeira medida é realizada a partir do cálculo da excentricidade, indicada pela equação 3-23.

$$E = \sum_{i=1}^4 E_i, \text{ com } E_i = \frac{1}{2} \frac{D_i - D'_i}{D_i + D'_i} \quad (3-23)$$


O valor “E” para qualquer forma simétrica em relação às 8 direções indicadas é igual a zero, aumentando a medida em que cresce a assimetria do objeto.

A segunda medida é chamada pelos autores de “vetor de raio médio” (VRM) e representa outro tipo de medida de simetria do objeto, cujo valor tende ao infinito para um objeto em forma de círculo. Esta medida é definida por:

$$VRM = \frac{1}{\sigma_D} \sum_{i=1}^4 D_i, \text{ onde } \sigma_D \text{ representa o desvio padrão das medidas } D_i.$$

Em 1975, William G. Wee *et al.* [WEE-75] propuseram o uso de sete atributos para a classificação de calcificações mamárias. As equações utilizadas para o cálculo dos fatores de forma e suavidade são descritos pelas equações 3-24 e 3-25, respectivamente.

$$Forma = \frac{1}{1PEM1} \sqrt{\sum_{N=1}^{1PEM1} [D(n) - D_{mean}]^2}, \quad \text{onde} \quad (3-24)$$

1PEM1 é o número de pontos da borda da calcificação

$X_n, Y_n$  são as coordenadas do pixel de borda  $n$  da calcificação

$NCX, NCY$  são as coordenadas do centro da calcificação

$$D(n) = \sqrt{(X_n - NCX)^2 + (Y_n - NCY)^2}$$

$$D_{mean} = \frac{1}{1PEM1} \left[ \sum_{N=1}^{1PEM1} \sqrt{(X_n - NCX)^2 + (Y_n - NCY)^2} \right]$$

$$suavidade = \sqrt{\frac{1}{NC} \sum_{K,L} [C(K,L) - NSPOT]^2}, \quad \text{onde} \quad (3-25)$$

$NC$  é a área da calcificação

$C(K, L)$  é o nível de cinza de cada pixel interno à microcalcificação

$NSPOT$  é o nível de cinza médio da calcificação (excluindo as áreas de buracos)

$K, L$  são as coordenadas da imagem

### 3.1.6 – Medidas de densidade intrapartícula

Outro fator importante na análise das microcalcificações é o contraste (referenciado por densidade pelos médicos) existente entre os pixels de borda e os pixels do centro. Essa medida é um indicativo do tipo de microcalcificação que esta sendo analisada. Microcalcificações ditas “perfuradas” ou “vazadas”, são aquelas que, de modo geral, se formam ao redor dos ductos possuindo portanto, grande variação de contraste entre seu centro e sua borda. Para indicar essa característica, J.Parker *et al.* [PARKER-93], propõem as seguintes medidas:

“foreground” - nível de cinza médio dos pixels do objeto

“background” - nível de cinza médio dos pixels 8-conectados da borda do objeto

“diferença” - “foreground” - “background”

$$\text{Contraste} = \frac{(\text{foreground} - \text{background})}{(\text{foreground} + \text{background})} \quad (3-26)$$

### 3.1.7 – Outras medidas de distribuição e número das microcalcificações

A distribuição e o número das microcalcificações dentro da ROI são fatores importantes para a caracterização do tipo de lesão de mama. Lesões benignas tendem a possuir microcalcificações mais espalhadas e em número menor, já nas lesões malignas é frequente o aparecimento de um grande número de microcalcificações próximas umas das outras. As equações abaixo descrevem algumas medidas que buscam quantificar essas características.

$$\text{Medida de distribuição} = \frac{\sigma^2}{\mu} \quad (3-27)$$

onde  $\mu$  e  $\sigma^2$  representam os valores da média e da variância, respectivamente, entre os valores de distância dos centróide de cada microcalcificação

$$\text{Fator Nro. Calcificação} = (1 - 0,75^{(\text{Nro. Calcificações na ROI})}) \quad (3-28)$$

O valor 0,75 foi ajustado de forma experimental a partir dos dois conjuntos de imagens; malignas e benignas.

### 3.1.8 – Medida de Excentricidade

A medida abaixo indica o grau de irregularidade de cada microcalcificação contida dentro ROI investigada.

$$\text{Excentricidade} = \frac{m_{20} + m_{02} + \sqrt{(m_{20} - m_{02})^2 + 4.(m_{11})^2}}{m_{20} + m_{02} - \sqrt{(m_{20} - m_{02})^2 + 4.(m_{11})^2}} \quad (3-29)$$

onde  $m_{ij}$  são momentos centrais de ordem  $(i+j)$ .

## 3.2 – Atributos de textura extraídos de regiões de interesse dos mamogramas

Além de medidas simples, como área e perímetro, vários trabalhos utilizam informações de textura extraídas de regiões de interesse da imagem para identificar possíveis ocorrências de lesões malignas.

Os casos de difícil diagnóstico são aqueles nos quais as microcalcificações não são claramente definidas e/ou visíveis. De acordo com [CHITRE-94], a segmentação automática dessas regiões frequentemente não produz uma solução única para a extração de bordas e informações de forma, afetando dessa forma a descrição dos atributos usados na classificação e causando um erro na caracterização das microcalcificações.

Em Yateen Chitre *et al.* [CHITRE-94], A.Petrosian, Heang-Ping Chan, Mark A. Helvie, Mitchell M. Goodsitt e Dorit D. Adler [PETROSIAN-94] e Heang-Ping Chan *et al.* [CHAN-97], os autores utilizaram informações de textura das imagens dos mamogramas digitalizados extraídas do histograma de segunda ordem. A vantagem dessa abordagem é que ela não requer a segmentação binária das microcalcificações para a classificação.

### 3.2.1 - Estatísticas do Histograma de Segunda Ordem

De acordo com [CHITRE-94], o histograma de nível de cinza de primeira ordem é definido como a distribuição de probabilidade de ocorrência de um nível de cinza na imagem. O histograma de segunda ordem,  $p(i,j)$ , também chamado de matriz de dependência espacial de nível de cinza ou matriz de co-ocorrência, é segundo Arun D. Kulkarni [KULKARNI-94] e [CHITRE-94], uma representação da distribuição de probabilidade de ocorrência de um par de valores de nível de cinza

separados por uma distância “d” na orientação “ $\theta$ ”. Em outras palavras,  $p(i,j)$  indica a frequência de ocorrência de um particular par de níveis de cinza  $i$  e  $j$ , medido a partir de uma distância “d” e de um ângulo “ $\theta$ ”.

As estatísticas do histograma de segunda ordem, de acordo com Y.M. Kadah, A. A. Farag, J.M. Zurada, A.M. Badawi e A.M. Youssef [KADAH-96] e Heang-Ping Chan *et. Al.* [CHAN-97], se correlacionam muito bem com as estruturas da imagem e têm sido largamente utilizadas na literatura para a análise de textura de imagens. Os atributos obtidos do histograma de segunda ordem comumente utilizados são: entropia, contraste, momento angular, correlação, inércia e homogeneidade local. A seguir são descritos os atributos de textura propostos por [HARALICK-73] e [CHAN-97].

### 3.2.1.1 - Entropia

A entropia calculada a partir do histograma de segunda ordem mede a não uniformidade da imagem e é definida como:

$$Entropia = - \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} p(i,j) \cdot \log_2[p(i,j) + \varepsilon] \quad (3-30)$$

onde  $\varepsilon$  é uma pequena constante positiva para evitar “overflow” quando  $p(i,j)$  for zero. Altos valores de medidas de uniformidade indicam baixa variação estrutural, enquanto baixos valores podem ser interpretados como alta probabilidade das estruturas contidas na imagem estarem relacionadas às microcalcificações.

### 3.2.1.2 - Contraste de $p(i,j)$

O contraste do histograma de segunda ordem é definido como:

$$Contraste = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} (i-j)^2 p(i,j) \quad (3-31)$$

Esta medida indica o quão aguda são as variações estruturais na imagem.



### 3.2.1.3 – Segundo Momento Angular (SMA) de $p(i,j)$

O segundo momento angular é uma medida poderosa da uniformidade e é definida como:

$$SMA \text{ de } p(i, j) = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} [p(i, j)]^2 \quad (3-32)$$

Altos valores de não-uniformidade indicam altas variações estruturais.

### 3.2.1.4 - Momento da diferença inversa

Este atributo é uma medida da homogeneidade local da imagem, e é definido como:

$$\text{Momento da diferença inversa} = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} \left[ \frac{1}{1+(i-j)^2} \right] p(i, j) \quad (3-33)$$

### 3.2.1.5 - Correlação de $p(i,j)$

O atributo correlação é definido como:

$$\text{Correlacao} = \frac{\sum_{i=0}^{n-1} \sum_{j=0}^{n-1} (i,j) p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (3-34)$$

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

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

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

onde  $\mu_x$ ,  $\mu_y$ ,  $\sigma_x$ ,  $\sigma_y$  e são as médias e os desvios padrão das distribuições marginais,  $p_x(i)$ ,  $p_y(j)$ , unidimensionais do histograma de segunda ordem  $p(i,j)$ . O atributo correlação é uma medida da dependência linear entre os níveis de cinza de uma imagem.

### 3.2.1.6 – Média, Variância e Entropia de $p_{x+y}$

$$\text{Média da Soma} = \sum_{k=0}^{2n-2} kp_{x+y}(k) \quad (3-35)$$

$$\text{Variância da Soma} = \sum_{k=0}^{2n-2} (k - \text{Média da Soma})^2 p_{x+y}(k) \quad (3-36)$$

$$\text{Entropia da Soma} = - \sum_{k=0}^{2n-2} p_{x+y}(k) \cdot \log_2[p_{x+y}(k)] \quad (3-37)$$

onde  $p_{x+y}(k) = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} p(i, j)$ ,  $i + j = k$   $k = 0, \dots, 2n - 2$ . é chamado de histograma de segunda ordem da soma e representa a probabilidade de ocorrência da soma dos pixels  $(i+j)$  na imagem.

### 3.2.1.7 – Média, Variância e Entropia de $p_{x-y}$

$$\text{Média da Diferença} = \sum_{k=0}^{n-1} kp_{x-y}(k) \quad (3-38)$$

$$\text{Variância da Diferença} = \sum_{k=0}^{n-1} (k - \text{Média da Diferença})^2 p_{x-y}(k) \quad (3-39)$$

$$\text{Entropia da Diferença} = - \sum_{k=0}^{n-1} p_{x-y}(k) \cdot \log_2 p_{x-y}(k) \quad (3-40)$$

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

é chamado de histograma de segunda ordem da diferença e representa a probabilidade de ocorrência da diferença dos pixels  $(i-j)$  na imagem.

### 3.2.1.8 – Medidas de informação de correlação 1 e 2 (Mic\_1 e Mic\_2)

$$Mic\_1 = \frac{(Entropia - H_1)}{\max\{H_x, H_y\}} \quad (3-41)$$

$$Mic\_2 = \sqrt{1 - \exp[-2 \cdot (H_2 - Entropia)]} \quad (3-42)$$

onde

$$H_1 = - \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} p(i, j) \log_2 [p_x(i) \cdot p_y(j)] \quad (3-43)$$

$$H_2 = - \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} p_x(i) \cdot p_y(j) \cdot \log_2 [p_x(i) \cdot p_y(j)] \quad (3-44)$$

$$H_x = - \sum_{i=0}^{n-1} p_x(i) \cdot \log_2 p_x(i) \quad (3-45)$$

$$H_y = - \sum_{j=0}^{n-1} p_y(j) \cdot \log_2 p_y(j) \quad (3-46)$$

# Capítulo 4

## Técnicas utilizadas para a seleção e classificação de atributos

Segundo E.J. Ciaccio, S.M. Dunn e M.Akay [CIACCIO-93A] e H. Dickhaus *et al* [DICKHAUS-96] a classificação de padrões pode ser subdividida em 3 etapas principais: a extração de atributos, que é o processo pelo qual o padrão é convertido em medidas ou atributos, a seleção que é a etapa de redução do número de atributos através da eliminação da correlação existente entre eles e a classificação propriamente dita.



Figura 4.1 - Etapas da Classificação - [DICKHAUS-96]

### 4.1 – Técnicas para a seleção de atributos

Segundo [FUKUNAGA-90], a seleção de atributos é geralmente considerada um processo de mapeamento de medidas originais (medidas realizadas no padrão) para atributos mais efetivos. Se o mapeamento é linear, a função mapeamento é bem definida e portanto basta encontrar os coeficientes da função linear de forma a maximizar ou minimizar um determinado critério. Entretanto, em muitas aplicações de reconhecimento de padrão, existem atributos importantes que não são funções lineares de medidas originais, tornando o problema mais complexo.

É extremamente importante observar a escolha dos atributos, pois segundo Richard O. Duda e Peter E. Hart [DUDA-73] os atributos podem ter as seguintes limitações:

a) podem ser inadequados para distinguir as diferentes classes, ou seja, podem não conter informações necessárias para separar as classes.

b) podem estar altamente correlacionados, e dessa forma expressarão a mesma dimensão do padrão, ou seja, diferentes atributos são influenciados pelo mesmo mecanismo comum e tendem a variar juntos.

c) Existência de subclasses dentre os atributos que não foram identificadas

Várias são as metodologias empregadas na seleção de atributos. De acordo com [MASCARENHAS-89], estas técnicas podem ser divididas em duas categorias: transformações no espaço de atributos ou medidas de informação e distância.

Técnicas de transformações no espaço de atributos têm por objetivo transformar o espaço de atributos originais em um espaço com menor dimensionalidade, preservando ao máximo a representação dos padrões e/ou a discriminação entre as classes. Nessa classe destacam-se a transformação de Karhunen-Loève e a função discriminante de Fisher.

Por outro lado, técnicas de medidas de informação e distância, não reduzem o espaço de atributos, mas dão uma idéia do quão sobrepostas estão as classes. Nesse grupo destacam-se: medida de divergência, distância Jeffries-Matusita e distância de Bhattacharyya.

Outra metodologia bastante empregada consiste na utilização de arquiteturas de Redes Neurais Artificiais (RNA).

## **4.2 – Técnicas estatísticas utilizadas na classificação de lesões de mama**

De acordo com [KADAH-96], as técnicas de classificação estatísticas podem ser divididas em paramétricas e não-paramétricas. O reconhecimento de

padrões estatístico paramétrico usa ou assume informações sobre as probabilidades *a priori* para realizar a classificação. Por outro lado, segundo E.J. Ciaccio, S.M. Dunn e M. Akay [CIACCIO-93B], quando a forma funcional das densidades de probabilidade não são conhecidas, recorre-se às chamadas técnicas não-paramétricas.

Segundo [MASCARENHAS-89], [FUKUNAGA-90] e [CHITRE-94], o uso de métodos paramétricos multivariados, como classificadores lineares e quadráticos assumindo uma distribuição de densidade normal das amostras, são largamente utilizados em reconhecimento de padrão estatístico. O desempenho desses tipos de classificadores está diretamente relacionado à distribuição dos atributos no espaço de atributos. Normalmente, para efeito de simplificação do problema, assume-se a distribuição da classe de padrões como uma Gaussiana, ([CIACCIO-93B]).

#### 4.2.1 – Teoria de decisão de Bayes

Nessa seção, onde é apresentada a teoria de decisão de Bayes, será utilizada a seguinte nomenclatura:

a) o problema de classificação será formulado a partir de  $c$  classes  $w_i$  ( $i=1, \dots, c$ ) com probabilidades de ocorrência (probabilidades *a priori*) dadas por

$$P(w_i), \text{ onde } P(w_i) \geq 0 \text{ e } \sum_1^c P(w_i) = 1.$$

b) o vetor de medidas (vetor de atributos), a função de probabilidade condicional e a probabilidade *a posteriori* de cada uma das  $c$  classes  $w_i$  serão indicadas por  $\mathbf{x}$ ,  $p(\mathbf{x}|w_i)$  e  $P(w_i|\mathbf{x})$ , respectivamente.

c) a decisão por uma classe  $i$  será dada por  $w(\mathbf{x}) = w_i$ , e no caso de rejeição do padrão a indicação será  $w(\mathbf{x}) = w_0$ . Na existência da hipótese de rejeição, existirão  $(c+1)$  decisões para um problema de  $c$  classes.

d) o custo de decisão ou perda em decidir-se por  $w_i$  quando o estado da natureza é  $w_j$  será indicado por  $\lambda(w_i|w_j)$ .

A abordagem bayesiana de um problema de classificação parte do princípio que o vetor de medidas  $\mathbf{x}$  extraído de um padrão é aleatório, uma vez que

tal teoria envolve as probabilidades *a priori* e as funções densidades de probabilidade  $p(\mathbf{x}|w_i)$  de cada classe.

Nos diversos trabalhos apresentados na literatura grande parte dos autores classificam as lesões de mama, em benignas ou malignas, a partir de informações extraídas das imagens dos mamogramas digitalizados. De acordo com o grau de informação *a priori* do problema tem-se classificadores simples ou mais complexos. Vários autores, por não possuírem informações precisas sobre o problema, buscam a solução em modelos mais simples. Dessa forma, quase sempre assumem as probabilidades de ocorrência das lesões malignas e benignas como sendo iguais numa dada população, e os custos ou perdas,  $\lambda(w_i|w_j)$ , do falso-positivo e do falso-negativo (possíveis erros de classificação) também iguais.

#### 4.2.1.1 – Regra de Bayes para o mínimo erro (sem rejeição)

Na abordagem bayesiana de mínimo erro sem rejeição, a matriz de custo é do tipo 0-1, ou seja,  $\lambda(w_1|w_1) = \lambda(w_2|w_2) = 0$  e  $\lambda(w_1|w_2) = \lambda(w_2|w_1) = 1$ . Dessa forma, os custos do falso-positivo e do falso-negativo são considerados iguais a 1 e o custo do acerto como sendo 0. Portanto, o mínimo erro ocorre quando se tem a máxima probabilidade *a posteriori*. Para um problema de classificação envolvendo duas classes  $w_1$  e  $w_2$ , sem rejeição, a regra de Bayes para o mínimo erro pode ser formulada da seguinte maneira:

$$P(w_1 | \mathbf{x}) \underset{w_2}{\overset{w_1}{>}} P(w_2 | \mathbf{x}) \quad (4-1)$$

ou seja, se a probabilidade de  $w_1$  dado  $\mathbf{x}$  é maior que a probabilidade de  $w_2$ ,  $\mathbf{x}$  é classificado como  $w_1$ , caso contrário classifica-se  $\mathbf{x}$  como  $w_2$  ( [DUDA-73], [MASCARENHAS-89] e [FUKUNAGA-90] ).

A probabilidade *a posteriori*  $P(w_i|\mathbf{x})$  pode ser calculada a partir da probabilidade *a priori*  $P(w_i)$  e da função densidade condicional  $p(\mathbf{x}|w_i)$  usando a regra de Bayes, dada por:

$$P(w_j | \mathbf{x}) = \frac{p(\mathbf{x} | w_j)P(w_j)}{p(\mathbf{x})} \quad , \text{ onde} \quad (4-2)$$

$p(\mathbf{x}) = \sum_{i=1}^c p(\mathbf{x} | w_i)P(w_i)$  é a função densidade da mistura.

Substituindo a equação 4-2 na equação 4-1 e observando que  $p(\mathbf{x})$  é positiva e comum para ambos os lados da equação 4-1, a regra de decisão pode ser expressa por:

$$p(\mathbf{x} | w_1)P(w_1) \begin{matrix} > \\ < \end{matrix} p(\mathbf{x} | w_2)P(w_2) \quad , \text{ ou} \quad (4-3)$$

$$l(\mathbf{x}) = \frac{p(\mathbf{x} | w_1)}{p(\mathbf{x} | w_2)} \begin{matrix} > \\ < \end{matrix} \frac{P(w_2)}{P(w_1)} \quad , \text{ onde } l(\mathbf{x}) \text{ é chamado de razão de verossimilhança}$$

Quando as probabilidades *a priori* são iguais,  $P(w_1) = P(w_2)$ , tem-se o caso particular onde a decisão é realizada observando-se o maior valor das funções densidades condicionais,  $p(\mathbf{x}|w_1)$  e  $p(\mathbf{x}|w_2)$ , dado o vetor observação  $\mathbf{x}$ . Tal decisão é chamada de “decisão por máxima verossimilhança”, ([MASCARENHAS-89]). Por outro lado, se  $P(w_1) \neq P(w_2)$ , a decisão é feita pela máxima probabilidade *a posteriori* ou decisão MAP.

Em 1994, Woods *et al* [WOODS-94] publicaram um artigo avaliando o desempenho de diversas técnicas de classificação. Dentre as técnicas analisadas, os autores utilizaram, sob hipótese Gaussiana, a razão de máxima verossimilhança sobre uma amostra de treinamento para ajustar o nível de limiar  $\alpha = \frac{P(w_1)}{P(w_2)}$ . Após o ajuste do limiar  $\alpha$ , os autores utilizaram matrizes de covariâncias  $\Sigma_1 = \Sigma_2$  e  $\Sigma_1 \neq \Sigma_2$ , estimadas das amostras, para a implementação dos classificadores linear e quadrático, respectivamente. Segundo Woods, o ajuste do limiar  $\alpha$  diminuiu a taxa de falso-positivos.

#### 4.2.1.2 – Regra de Bayes para o mínimo erro (com rejeição)



Nas classificações visuais de lesões de mama, realizadas por médicos especialistas, algumas vezes faz-se necessário o emprego de uma outra modalidade de exame para que se consiga maior exatidão no diagnóstico. Essa falta de precisão deve-se principalmente às limitações do exame. Dessa forma, a introdução de um limiar de rejeição no projeto do classificador é um recurso muito importante, uma vez que os casos rejeitados poderão ser melhor diagnosticados através de outros métodos.

A formulação bayesiana para o mínimo erro de classificação com rejeição, para duas classes, onde a matriz de custo é  $\lambda = \begin{bmatrix} \lambda_r & \lambda_r \\ 0 & 1 \\ 1 & 0 \end{bmatrix}$ , é dada por:

$$w(\mathbf{x}) = w_i \quad \text{se } E^i \leq \lambda_r \quad (4-4)$$

$$w(\mathbf{x}) = w_0 \quad \text{se } E^i > \lambda_r \quad (4-5)$$

onde  $E^i$  é o erro de classificação associado à decisão  $w_i$  e  $\lambda_r$  é o limiar de rejeição.

Como  $E^i = 1 - P(w_i | \mathbf{x})$ , então, uma outra forma de se tomar a decisão é:

$$w(\mathbf{x}) = w_i \quad \text{se } P(w_i | \mathbf{x}) = \max_{j=1,2} \{ P(w_j | \mathbf{x}) \} \geq 1 - \lambda_r \quad (4-6)$$

$$w(\mathbf{x}) = w_0 \quad \text{se } 1 - \lambda_r > \max_{j=1,2} \{ P(w_j | \mathbf{x}) \} \quad (4-7)$$

para  $0 < \lambda_r < 0.5$

#### 4.2.1.3 – Regra de Bayes para mínimo risco (sem rejeição)

Na prática, nem sempre a melhor maneira de se tomar uma decisão é minimizando a probabilidade de erro de classificação, uma vez que os erros associados a cada decisão podem ter diferentes conseqüências, ([FUKUNAGA-90]). É evidente que classificar uma lesão de mama como benigna quando a decisão correta é maligna é bem pior que o contrário, ou seja, o custo do falso-negativo é bem maior que o custo do falso-positivo. Dessa forma, é apropriado associar diferentes custos à cada situação.

Como visto, o custo de decisão ou perda em decidir-se por  $w_i$  quando o estado da natureza é  $w_j$  é indicado por  $\lambda(w_i|w_j)$ .

O risco condicional ou risco de Bayes em decidir  $x \in w_i$  dado  $x$  é :

$$R^i(\mathbf{x}) = \sum_{j=1}^c \lambda(w_i | w_j) P(w_j | \mathbf{x}) \quad (4-8)$$

Portanto, para um problema de classificação envolvendo duas classes  $w_1$  e  $w_2$ , a regra de decisão para o mínimo risco condicional dado  $x$  é:

$$R^1(\mathbf{x}) \underset{w_1}{>} R^2(\mathbf{x}) \quad (4-9)$$

Substituindo a equação 4-8, calculada para as classes  $w_1$  e  $w_2$ , na equação 4-9 tem-se:

(4-10)

$$\lambda(w_1 | w_1) P(w_1 | \mathbf{x}) + \lambda(w_1 | w_2) P(w_2 | \mathbf{x}) \underset{w_1}{>} \lambda(w_2 | w_1) P(w_1 | \mathbf{x}) + \lambda(w_2 | w_2) P(w_2 | \mathbf{x})$$

Manipulando os termos da equação 4-10 e observando que  $\lambda(w_1|w_1) < \lambda(w_1|w_2)$  e  $\lambda(w_2|w_2) < \lambda(w_2|w_1)$ , então:

$$\frac{P(w_1 | \mathbf{x})}{P(w_2 | \mathbf{x})} \underset{w_2}{>} \frac{\lambda(w_2 | w_1) - \lambda(w_2 | w_2)}{\lambda(w_1 | w_2) - \lambda(w_1 | w_1)} \quad (4-11)$$

ou, através da regra de Bayes :

$$\frac{p(\mathbf{x} | w_1)}{p(\mathbf{x} | w_2)} \underset{w_2}{>} \left( \frac{\lambda(w_2 | w_1) - \lambda(w_2 | w_2)}{\lambda(w_1 | w_2) - \lambda(w_1 | w_1)} \right) \frac{P(w_2)}{P(w_1)} \quad (4-12)$$

Novamente, como na regra de Bayes para o mínimo erro, quando  $P(w_1) = P(w_2)$  e matriz de custos 0-1 ( $\lambda(w_1|w_1) = \lambda(w_2|w_2) = 0$  e  $\lambda(w_1|w_2) = \lambda(w_2|w_1) = 1$ ), chega-se a regra de decisão por “máxima verossimilhança”. De outra forma, quando  $P(w_1) \neq P(w_2)$  e matriz de custos 0-1, tem-se a regra de decisão por “máxima probabilidade *a posteriori*” ou decisão MAP.

Em um artigo publicado em 1994, Y. Chitre *et al* [CHITRE-94] implementaram diversas técnicas para a classificação de microcalcificações



mamográficas. Dentre elas, dois classificadores com abordagem bayesiana foram utilizados. Assumindo o modelo gaussiano, onde

(4-13)

$$p(\mathbf{x}|w_i) \sim N(\mathbf{m}_i, \Sigma_i) = \frac{1}{(2\pi)^{d/2} |\Sigma_i|^{1/2}} \exp\left[-\frac{1}{2}(\mathbf{x} - \mathbf{m}_i)^T \Sigma_i^{-1} (\mathbf{x} - \mathbf{m}_i)\right] \quad \text{para } i=1, \dots, 2$$

e a matriz de custos é

$$\lambda = \begin{bmatrix} 0 & \lambda(w_1 | w_2) \\ \lambda(w_2 | w_1) & 0 \end{bmatrix}, \text{ com } \lambda(w_1 | w_2) \neq \lambda(w_2 | w_1),$$

os autores obtiveram dois classificadores. O primeiro deles, com  $\Sigma_1 = \Sigma_2$ , é um classificador linear, ou seja, a função de separação entre as classes é um hiperplano.

A regra de decisão implementada fica:

Dado o vetor de medidas  $\mathbf{x}$ ,  $\mathbf{x} \in w_1$  se

$$(\mathbf{m}_1 - \mathbf{m}_2)^T \Sigma^{-1} \mathbf{x} - \frac{1}{2} (\mathbf{m}_1 - \mathbf{m}_2)^T \Sigma^{-1} (\mathbf{m}_1 - \mathbf{m}_2) \geq \ln \left[ \frac{\lambda(w_1 | w_2) P(w_2)}{\lambda(w_1 | w_2) P(w_1)} \right] \quad (4-14)$$

caso contrário  $\mathbf{x} \in w_2$ .

O segundo classificador é do tipo quadrático, pois implementa uma superfície de separação hiperquadrática, uma vez que  $\Sigma_1 \neq \Sigma_2$ . A regra de decisão é dada por:

Dado o vetor de medidas  $\mathbf{x}$ ,  $\mathbf{x} \in w_1$  se

(4-15)

$$-\frac{1}{2} \mathbf{x}^T (\Sigma_1^{-1} - \Sigma_2^{-1}) \mathbf{x} + (\mathbf{m}_1 \Sigma_1^{-1} - \mathbf{m}_2 \Sigma_2^{-1}) \mathbf{x} - k \geq \ln \left[ \frac{\lambda(w_1 | w_2) P(w_2)}{\lambda(w_1 | w_2) P(w_1)} \right], \text{ onde}$$

$$k = \frac{1}{2} \ln \left[ \frac{|\Sigma_1|}{|\Sigma_2|} \right] + \frac{1}{2} (\mathbf{m}_1^T \Sigma_1^{-1} \mathbf{m}_1 - \mathbf{m}_2^T \Sigma_2^{-1} \mathbf{m}_2) \quad (4-16)$$

caso contrário  $\mathbf{x} \in w_2$ .

A estimativa por “máxima verossimilhança” foi utilizada para estimar o vetor de médias e as matrizes de covariância de ambas as classes. No caso do classificador linear a matriz de covariância foi calculada através da média das matrizes de covariância das duas classes.

#### 4.2.1.4 – Regra de Bayes para mínimo risco (com rejeição)

Para o problema envolvendo duas classes, a abordagem bayesiana para mínimo risco com rejeição envolve a introdução de uma terceira classe (“classe rejeição”). Portanto tem-se a seguinte regra de decisão:

$$w(\mathbf{x}) = w_i \quad \text{se} \quad R(x) = \min_{i=0,1,2} R^i(x) \quad (4-17)$$

$R^i(x)$  é o risco condicional ou risco de Bayes indicado na equação 4-8.

Ou seja, escolhe-se a classe  $w_i$ , cujo risco médio ou risco de Bayes seja o menor entre as 3 classes. A regra de Bayes para mínimo risco com rejeição é extremamente importante na classificação de lesões de mama pois, além de classificar a lesão desconhecida minimizando o risco de erro da classificação, permite ainda a possibilidade da indicação da necessidade de mais informações para o processo de classificação no caso de rejeição do padrão.

#### 4.2.1.5 – Treinamento e Aprendizado

Na seção 4.2.1 o problema de classificação foi abordado através da Teoria de Bayes, levando-se em consideração que as densidades condicionais das classes “lesão maligna” e “lesão benigna” eram conhecidas. Em aplicações de Reconhecimento de Padrões raramente tem-se o completo conhecimento sobre as estruturas probabilísticas do problema. De acordo com [DUDA-73], [MASCARENHAS-89] e [FUKUNAGA-90], quando a forma funcional das densidades é conhecida (ou assumida), exceto por seus parâmetros, tem-se o problema de aprendizado, que é um processo de estimação dos parâmetros desconhecidos. Quando existem amostras disponíveis de classificação conhecida (amostras rotuladas), diz-se que o problema de aprendizado é supervisionado.

Para determinar os valores dos parâmetros desconhecidos, dois modelos podem ser adotados: se os parâmetros a serem estimados são considerados não-aleatórios, as técnicas de estimação por máxima verossimilhança podem ser

empregadas. Já na situação em que os parâmetros são considerados variáveis aleatórias, cai-se num esquema Bayesiano.

Nos trabalhos apresentados por Yateen Chitre *et al.* [CHITRE-94] e Kevin S. Woods *et al.* [WOODS-94], os autores assumiram a forma gaussiana para as funções densidades condicionais, sendo os parâmetros, vetor de médias e matriz de covariância, estimados por máxima verossimilhança. Dessa forma, os valores esperados são calculados através das seguintes equações:

$$\mathbf{m}_i = \frac{1}{N_i} \sum_{j=1}^{N_i} \mathbf{x}_j \quad \text{e} \quad (4-18)$$

$$\Sigma_i = \frac{1}{N_i} \sum_{j=1}^{N_i} (\mathbf{x}_j - \mathbf{m}_i)(\mathbf{x}_j - \mathbf{m}_i)^T \quad (4-19)$$

com  $\mathbf{m}_i$  e  $\Sigma_i$  representando o vetor de médias e a matriz de covariância da classe  $i$ , respectivamente.

Esses estimadores podem ser expressos de forma recursiva, como indicado a seguir:

$$\mathbf{m}_i(N_i + 1) = \frac{1}{N_i + 1} (N_i \cdot \mathbf{m}_i(N_i) + \mathbf{x}_{N_i+1}) \quad \text{e} \quad (4-20)$$

$$\begin{aligned} \Sigma_i(N_i + 1) = & \frac{1}{N_i + 1} (N_i \cdot \Sigma_i(N_i) + N_i \cdot \mathbf{m}_i(N_i) \cdot \mathbf{m}_i^T(N_i) + \mathbf{x}_{N_i+1} \cdot \mathbf{x}_{N_i+1}^T) - \\ & \frac{1}{(N_i + 1)^2} (N_i \cdot \mathbf{m}_i(N_i) + \mathbf{x}_{N_i+1})(N_i \cdot \mathbf{m}_i(N_i) + \mathbf{x}_{N_i+1})^T \end{aligned} \quad (4-21)$$

onde  $N_i$  é o número de amostra. O processo de recursão inicia-se com:

$$\mathbf{m}_i(1) = \mathbf{x}_1 \quad (4-22)$$

$$\Sigma_i(1) = \mathbf{x}_1 \cdot \mathbf{x}_1^T - \mathbf{m}_i(1) \cdot \mathbf{m}_i^T(1) = 0 \quad (4-23)$$

Após a estimação, os parâmetros calculados são então “injetados” nas funções densidades condicionais do classificador – regra de decisão do tipo “Plug-In” –.

## 4.2.2 – Método K-NN (K-vizinho mais próximo)

O método K-NN é uma extensão da regra vizinho mais próximo (NN), e realiza a classificação de um vetor de atributos  $x$  extraído de um padrão desconhecido, associando-o a classe com o maior número de representantes dentre as  $K$  amostras vizinhas; em outras palavras, a decisão é realizada através da verificação dos rótulos dos  $K$ -vizinhos mais próximos, ([DUDA-73]). Os  $K$  objetos mais similares ao padrão desconhecido são encontrados através de uma medida de similaridade (como a distância Euclidiana, Mahalanobis, etc) no espaço de atributos. De acordo com [PARKER-93], é possível também ajustar um número mínimo de representantes pertencentes às  $K$ -amostras vizinhas, dando uma maior confiança à classificação do padrão desconhecido. Segundo [DUDA-73] e [LAAKSONEN-96], a taxa de erro assintótica quando o número de amostras de treinamento é muito grande, aproxima-se do erro ótimo de Bayes e tende a ele quando  $K$  vai para o infinito. A principal desvantagem desse método é a grande carga computacional que ele exige, uma vez que para classificar um objeto desconhecido " $O$ ", é necessário o cálculo das distâncias entre o vetor de atributos do objeto " $O$ " e os vetores de atributos de cada objeto do grupo de treinamento.

A seguir é apresentado o algoritmo básico para a implementação do classificador K-NN.

1ºPasso) Obter e armazenar as distâncias entre o vetor de atributos do padrão desconhecido e todos os vetores de atributos dos padrões pertencentes ao grupo de treinamento.

2ºPasso) Relacionar em ordem crescente os valores das distâncias calculadas no 1º Passo.

3ºPasso) Considerar o subgrupo dos valores das  $K$ -primeiras distâncias do grupo ordenado no 2º Passo, e conhecendo o número de representantes de cada classe dessas amostras, associar o padrão desconhecido a classe que possuir o maior número de representantes neste subgrupo analisado se ele existir, caso contrário o resultado é considerado não conclusivo (rejeição).

4ºPasso) Estimar a taxa de erro pela comparação dos resultados da classificação com os arquivos verdadeiros. Tratar os casos especiais de decisão não-conclusiva individualmente como entidades separadas e obter sua taxa de ocorrência.

### 4.2.3 – Redes Neurais

Nos últimos 10 anos, vários pesquisadores têm investigado o uso de arquiteturas de Redes Neurais Artificiais (RNAs) para a detecção e classificação de lesões de mama. Em geral RNAs são caracterizadas por: um grande número de elementos simples de processamento (nós); um grande número de elementos de conexão entre os nós (pesos), os quais armazenam o conhecimento adquirido; alto paralelismo, controle distribuído e habilidade para aprender automaticamente as representações internas (atualizações das interconexões). Os nós de processamento executam a soma dos pesos de suas entradas, calculando um simples valor de saída através de alguma função de ativação não-linear. Os nós são ditos ativados se o valor de ativação for maior que um determinado valor de “threshold” ajustável, associado aquele nó.

A topologia da rede refere-se à forma como a interconexão dos nós está organizada. O conhecimento da rede é armazenado nos pesos das interconexões, e é o algoritmo de treinamento que especifica os valores iniciais dos pesos e como eles serão atualizados para melhorar o desempenho da rede. De uma forma geral, as RNAs podem ser descritas através das características de seus nós, da topologia da rede, e do algoritmo de treinamento utilizado para treiná-la.

As RNAs geralmente são classificadas a partir da sua topologia, dividindo-se em três principais categorias: redes supervisionadas, recorrentes e auto-organizantes. As RNAs supervisionadas usam conhecimento prévio sobre as saídas desejadas, de maneira que o erro entre a entrada atual e a saída esperada sejam minimizados. Redes recorrentes utilizam a medida do erro global mas não necessitam da saída exata. Por fim, as redes auto-organizantes (ou redes de Kohonen) determinam por elas mesmas as representações dos pesos internos a partir

de uma determinada entrada, não havendo necessidade de supervisão ([FAUSETT-94]).

Uma das RNAs mais comumente utilizadas em reconhecimento de padrões é a MLP (“multi-layer perceptron”) ou perceptron multi-camadas. Este tipo de rede por ser supervisionada necessita de amostras rotuladas para ajustar os seus pesos. A arquitetura, número de camadas intermediárias e nós, juntamente com os parâmetros de treinamento são previamente ajustados e através do algoritmo “backpropagation” a rede é capaz de determinar o melhor grupo de pesos para os quais se tem o mínimo erro quadrático (erro entre entrada atual e saída desejada).



# Capítulo 5

## Conclusões do estudo realizado

Como já mencionado, o número de trabalhos para a detecção e classificação de microcalcificações em mamogramas digitalizados é grande. A maioria deles empregam técnicas com características diferentes tornando inviável uma análise comparativa aplicada de cada um. Além disso, a escolha dos melhores métodos para a classificação de lesões de mama através da comparação direta dos seus resultados é difícil devido a vários fatores. O primeiro fator está associado ao uso de bases de dados diferentes, ([NISHIKAWA-92]) (variação em número e em qualidade das imagens), com características de digitalização diferentes. De acordo com H.P.Chan *et al.* [CHAN-94], as características utilizadas na digitalização dos mamogramas influenciam diretamente nas etapas de detecção e segmentação das microcalcificações. Dois outros fatores que também devem ser levados em consideração ao se analisar os resultados dos algoritmos de classificação, são os resultados obtidos nas etapas de detecção e segmentação das microcalcificações, uma vez que o número de microcalcificações detectadas em uma ROI e a forma das microcalcificações segmentadas são características importantes para o bom desempenho da etapa de classificação.

Apesar da forma da microcalcificação ser uma das principais características na caracterização de uma lesão de mama, ela por si só não é conclusiva, sendo necessárias outras informações, observadas numa análise de contexto. Portanto, informações de contraste e forma das microcalcificações, e de textura da ROI analisada, quando utilizadas em conjunto podem representar de maneira mais adequada as diferenças entre as lesões de mama benigna e malignas. O uso de um esquema de classificação multi-estágios pode também ser útil para a análise global do problema.

Por fim, é importante observar que apesar de existirem vários trabalhos voltados à detecção e classificação de lesões de mama, nenhum deles é conclusivo, e novos atributos e esquemas de classificação podem ainda ser avaliados.

## 5.1 - Considerações sobre os atributos utilizados na classificação

De acordo com os artigos apresentados no capítulo 2, os atributos podem ser divididos em: atributos de forma, de textura e de contraste. Atributos de forma são utilizados para análise das formas das microcalcificações, uma vez que essa informação pode evidenciar a presença ou não de uma lesão de mama. É importante notar que a representação da borda das microcalcificações, da forma mais exata possível, é um fator essencial para que os atributos que utilizam esse tipo de informação possam ser úteis a classificação. Dessa forma, fatores como resolução espacial e de contraste têm influência direta sobre os seus valores. A resolução espacial dá a dimensão da menor estrutura que pode ser analisada na imagem, e a resolução de contraste é fundamental para que algoritmos de segmentação baseados em "threshold" de nível de cinza possam determinar o exato delineamento das bordas das microcalcificações.

Outra informação muito utilizada na classificação de lesões de mama é a textura das regiões suspeitas do mamograma digitalizado. Segundo [CHAN-97], atributos extraídos a partir da matriz de co-ocorrência de níveis de cinza, geralmente contém informações sobre as características da imagem, tais como: homogeneidade, contraste, presença de estruturas organizadas, transição de nível de cinza e complexidade da imagem. Imagens de mamas saudáveis geralmente possuem uma distribuição mais suave dos níveis de cinza apresentando-se de maneira organizada, ao contrário de imagens contendo lesões malignas onde aparecem microcalcificações agrupadas e irregulares. Apesar das informações de textura poderem ser obtidas através de outros métodos (espectro de Fourier, análise fractal, transformada de Wavelets, entre outros), nos artigos analisados os autores obtiveram essas informações a partir da matriz de co-ocorrência de níveis de cinza. Os atributos de textura extraídos da matriz de co-ocorrência comumente utilizados para a classificação de lesões de mama são: entropia, contraste, homogeneidade local, momento angular, correlação e inércia.

De acordo com [PARKER-93], outra importante informação para a determinação da formação anátomo-patológica das microcalcificações é o contraste

existente entre seus pixels (pixels de borda e do interior). Microcalcificações formadas no interior dos ductos de leite da mama (intra-ductais) geralmente são mais densas e de baixo contraste possuindo um alto índice de malignidade associado. Por outro lado, microcalcificações com alto contraste geralmente estão localizadas ao redor dos ductos mamários e/ou nos lóbulos mamários, e possuem baixo índice de malignidade associado.

## **5.2 - Considerações sobre as técnicas de classificação**

Com relação as técnicas utilizadas na classificação das microcalcificações, pode ser observado que os artigos empregam basicamente 3 métodos: métodos estatísticos paramétricos, métodos estatísticos não-paramétricos e redes neurais artificiais. Dos métodos estatísticos paramétricos, o mais utilizado é o método de decisão de Bayes e dos métodos não-paramétricos o K-NN. Algoritmos de agrupamento de dados como o K-Médias e outras medidas de distância entre agrupamentos são mais utilizados para a seleção de grupos de atributos. Das arquiteturas de redes neurais, a mais utilizada é a “feedforward” treinada pelo algoritmo “backpropagation” com diferentes combinações no número de camadas e nós. Para grandes conjuntos de atributos, o algoritmo K-NN e algumas arquiteturas de redes neurais foram os que apresentaram melhores resultados. Já para o método de Bayes, os resultados obtidos são melhores para grupos reduzidos de atributos. De acordo com [WOODS-94], isso se deve a dificuldade em estimar as funções densidades condicionais para grandes conjuntos de atributos. Nos artigos que utilizam o método de Bayes, frequentemente é considerada a hipótese gaussiana para caracterizar as densidades multivariadas dos vetores de atributos. Nesses artigos, os vetores média e as matrizes de covariância de cada classe são estimados por máxima-verossimilhança, através das amostras rotuladas de cada classe.

# Capítulo 6

## Materiais e Métodos

Neste capítulo são descritos os principais métodos e equipamentos empregados para a realização deste trabalho de mestrado. No item 6.1 são descritas as características e a metodologia utilizada no desenvolvimento da base de dados de mamogramas digitalizados. Essa base de dados serviu para o treinamento e análise de desempenho dos classificadores. No item 6.2 são descritos os equipamentos e “softwares” utilizados na implementação dos programas. Por fim, no item 6.3 são apresentadas através de algoritmos e diagramas de blocos, as principais etapas do sistema de classificação (sistema de gerenciamento da base de dados, etapa de segmentação, atributos implementados, seleção dos principais atributos e classificação).

### 6.1 – Base de dados utilizada

A base de dados utilizada é composta por 200 imagens (50 diferentes casos – 25 benignos e 25 malignos) de mamogramas digitalizados contendo agrupamentos de microcalcificações. Esta base de dados foi desenvolvida junto ao Hospital das Clínicas da Faculdade de Medicina de Ribeirão Preto – USP, e é parte integrante deste trabalho. Para cada caso analisado foram selecionadas as projeções crânio-caudal e oblíqua das imagens das mamas esquerdas e direita. Todas as imagens são acompanhadas pelos correspondentes resultados da análise clínica das biópsias. As posições dos agrupamentos de microcalcificações em cada mamograma digitalizado foram identificadas por radiologistas experientes trabalhando juntamente

com os filmes originais, a fim de selecionar apenas agrupamentos positivos. As regiões de interesse dos filmes contendo os agrupamentos de microcalcificações em seu interior foram digitalizadas por um digitalizador “UMAX” modelo UC 1260 usando as seguintes características de digitalização:

amostragem (resolução espacial) : 600 DPI (pixel de 0.042 mm)

quantização (resolução de contraste): 8 bits (256 níveis de cinza)

digitalização por transmissão utilizando acessório acoplado.

Para a realização do treinamento e testes dos diferentes classificadores, as imagens da base de dados foram aleatoriamente organizadas usando a metodologia de validação “leave-k-out”. Esse método, conforme Lutz Prechelt [PRECHELT-94] em seu relatório técnico PROBEN1, consiste em dividir os grupos de dados (benigno e maligno) em k subgrupos de igual tamanho. O classificador é treinado k vezes, cada vez deixando um subgrupo fora do treinamento e usando-o apenas para o cálculo do desempenho do classificador. Nesse trabalho as amostras benigna e maligna foram divididas cada uma em 4 subgrupos com 25 amostras. As amostras de testes dos quatro grupos indicados na Tabela 6.1, foram organizadas de maneira que cada subgrupo foi utilizado apenas uma vez para os testes. Assim, por exemplo, as amostras de teste do Grupo 1 foram compostas pelos 1<sup>os</sup> subgrupos das classes benigna e maligna, sendo os demais utilizados para formar o grupo de treinamento. As amostras de teste do Grupo 2, foram compostas pelos 2<sup>os</sup> subgrupos e os demais foram usados para treinamento, e assim sucessivamente.

	Grupo1	Grupo2	Grupo3	Grupo4
<b>Treinamento</b>	75 malignas, 75 benignas	75 malignas, 75 benignas	75 malignas, 75 benignas	75 benignas, 75 benignas
<b>Teste</b>	25 benignas, 25 malignas	25 benignas, 25 malignas	25 benignas, 25 benignas	25 malignas, 25 benignas

Tabela 6.1 - Número de amostras utilizadas para treinamento e testes dos classificadores – método “leave-k-out”.

Dessa forma, para cada grupo são utilizadas 150 amostras para o treinamento (75 benignas e 75 malignas) e 50 amostras para o teste dos classificadores (25 benignas e 25 malignas). Esse procedimento é efetuado para evitar problemas de generalização.

## **6.2 – Microcomputador e softwares utilizados**

Para o desenvolvimento do sistema de gerenciamento das imagens e classificação foi utilizado um microcomputador IBM-PC compatível, com as seguintes características:

velocidade de processamento: 200 MHz

capacidade de memória RAM: 128MB

capacidade de memória em disco rígido: 3.2 GB

capacidade de memória da placa controladora de vídeo: 4 MB

monitor super-VGA com resolução: 1024x768 pixels

Os programas que compõem o sistema foram desenvolvidos no ambiente operacional “Windows-95”, utilizando a linguagem de programação “Pascal” orientada a objetos do software “Delphi 3.0 - Borland”. Os recursos visuais e as ferramentas de gerenciamento de banco de dados do software “Delphi 3.0” foram utilizadas para a elaboração das telas de “interface” do sistema e para a implementação e gerenciamento da base de dados de mamogramas digitalizados.

Para a implementação e testes das redes neurais artificiais perceptron multi-camadas (MLP- multi-layer perceptron), analisadas neste trabalho, foi utilizado o software “Matlab 5.0 for Windows” juntamente com o “Neural Network toolbox”, ambos da empresa “The Mathworks, Inc.”.

## 6.3 – Software Desenvolvido

Nesta seção são descritos os algoritmos dos programas desenvolvidos em cada etapa do sistema de classificação. O desenvolvimento do sistema pode ser dividido em 5 etapas principais. A primeira foi a elaboração de um programa de gerenciamento da base de dados para facilitar a manipulação e a organização das informações clínicas mais relevantes e utilizadas pelos médicos na tomada de decisão. Na segunda etapa foi realizada a segmentação das microcalcificações usando três diferentes técnicas. Na terceira etapa os principais atributos citados na literatura foram implementados para a caracterização das lesões de mama contendo microcalcificações associadas. Os atributos foram obtidos para cada imagem da base de dados. Na quarta etapa foi realizada a seleção dos atributos mais discriminatórios através das seguintes técnicas: o erro de Bayes e a distância de Jeffries-Matusita. Por fim, na quinta e última fase foram implementados três métodos para a classificação: regra de Bayes (paramétrico), K-NN (não-paramétrico) e RNA (semi-paramétrico). O diagrama de blocos geral do sistema é apresentado na Figura 6.1.

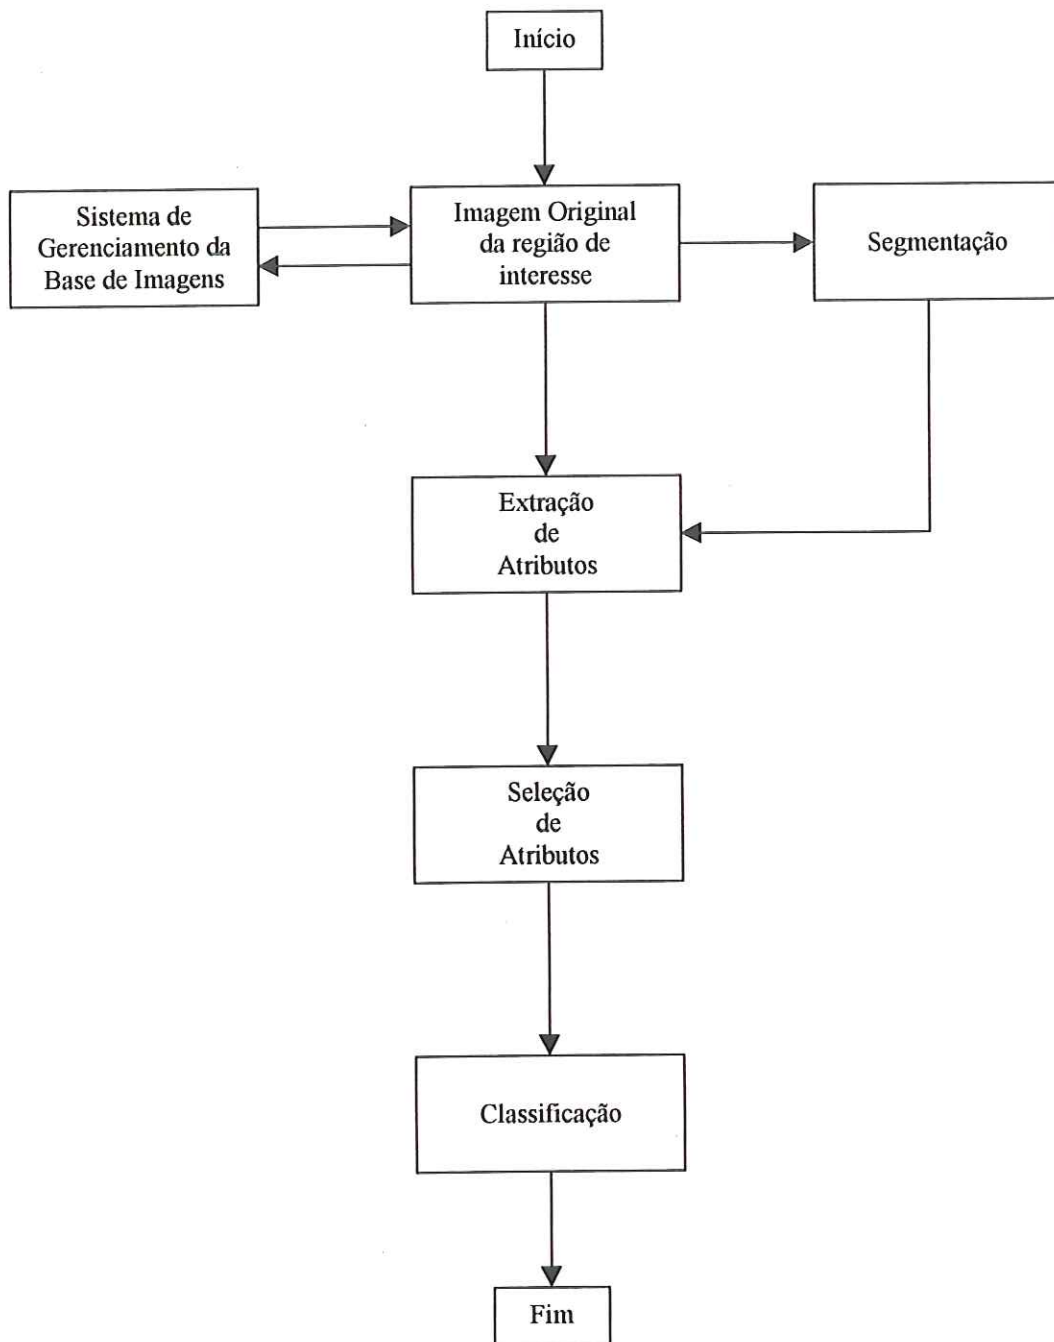


Figura 6.1 – Diagrama de blocos geral do sistema



### 6.3.1 – Programa de Gerenciamento da base de dados

Esse programa é composto por 4 seções principais: Identificação, Antecedentes, História da moléstia atual e alterações em exames, e Outras Informações. O programa permite realizar a associação dos mamogramas digitalizados (projeções crânio-caudal, médio lateral – esquerda e direita) às respectivas informações clínicas cadastradas. Dessa forma é possível realizar filtros sobre os dados armazenados através de chaves previamente definidas. As chaves selecionam os casos contendo: Nódulos, Microcalcificações, Nódulo + microcalcificações, Densidade Assimétrica, Densidade Assimétrica + microcalcificações, Lesões espiculadas e Normais. Uma vez selecionados os casos, as imagens podem ser visualizadas de forma automática dentro do sistema, através de um programa de visualização de imagens previamente indicado. As principais telas de entradas de dados do sistema são apresentadas no capítulo 7, seção 7.1.

### 6.3.2 – Método de Segmentação desenvolvido

O método de segmentação implementado é composto por 3 técnicas combinadas: método de “stretching” para a melhoria do contraste da imagem, imagem-diferença proposto por Robert M. Nishikawa, [NISHIKAWA-92], e um método de “thresholding” local adaptativo usado para binarizar a imagem.

#### 6.3.2.1 - Método “Stretching”

O método “stretching” ou linearização do histograma é um método simples mas muito utilizado em processamento de imagens e que tem por objetivo aumentar o contraste da imagem. Esse método foi aplicado a todas as ROIs antes da etapa de segmentação e extração de atributos para aumentar o contraste da imagem e

normalizar os níveis de cinza entre os limites máximo e mínimo da escala de tons de cinza. O algoritmo ALGO-6.3.2a ilustra brevemente este método.

ALGO-6.3.2a: método "stretching"

Início.

Encontrar os valores de cinza máximo ( $f_{\max}$ ) e mínimo ( $f_{\min}$ ) na imagem.

Aplicar a equação  $g(i, j) = \frac{255}{f_{\max} - f_{\min}} (f(i, j) - f_{\min})$  para cada pixel na imagem.

Fim.

Onde  $f(i, j)$  e  $g(i, j)$  são as imagens antes e depois da transformação, respectivamente.

### 6.3.2.2 - Imagem-diferença

Esta técnica foi apresentada inicialmente em [CHAN-87] onde os autores propõem um sistema de diagnóstico auxiliado por computador para detecção automática de microcalcificações em mamografias. A técnica imagem-diferença é usada para o realce das microcalcificações através da supressão das estruturas de fundo da imagem, causadas devido a anatomia normal da mama.

Este procedimento é realizado por dois filtros espaciais gerando uma imagem com as microcalcificações realçadas e outra com as microcalcificações suprimidas. Nesta última permanecem apenas as estruturas de fundo do mamograma, uma vez que os sinais são suprimidos. Subtraindo as duas imagens tem-se uma terceira imagem onde as altas variações de densidade de fundo foram removidas. A técnica de imagem-diferença apresentada neste trabalho é baseada no artigo [CHAN-88A], onde são usados os seguintes filtros: filtro "matched" para realce das microcalcificações ( Figura 6.2(a) ) e filtro "box-rim" para supressão das microcalcificações ( Figura 6.2(b) ).

A convolução do filtro "box-rim" com a imagem resulta na substituição dos sinais pela média da vizinhança do fundo, suavizando assim o ruído presente na imagem. A seleção dos tamanhos dos núcleos e da região central do filtro "box-rim" são determinados pelo tamanho dos sinais a serem removidos da imagem.

O filtro “matched” utilizado, apesar do nome, difere do filtro “matched” convencional uma vez que o tamanho e as formas das microcalcificações variam, sendo impossível projetar filtros que combinem exatamente cada diferente microcalcificação.

Na prática, os dois filtros são combinados em um único filtro linear com o núcleo ilustrado na Figura 6.2(c). O método "imagem-diferença" é descrito pelo algoritmo ALGO-6.3.2b.

*ALGO-6.3.2b* : método “imagem-diferença”

Início.

Criar máscara 9x9 pixels com núcleo combinado dado pela Figura 6.2(c).

Repete até Fim da Imagem Não Segmentada

    Ler janela de 9x9 pixels da imagem Não Segmentada, pixel central (x,y).

    Pixel (x,y) da Imagem Segmentada =  $\Sigma$  { Pixels (i,j) da janela \* pixel (i,j) da máscara}.

    Avança a janela 1 pixel.

FimRepete

Fim.

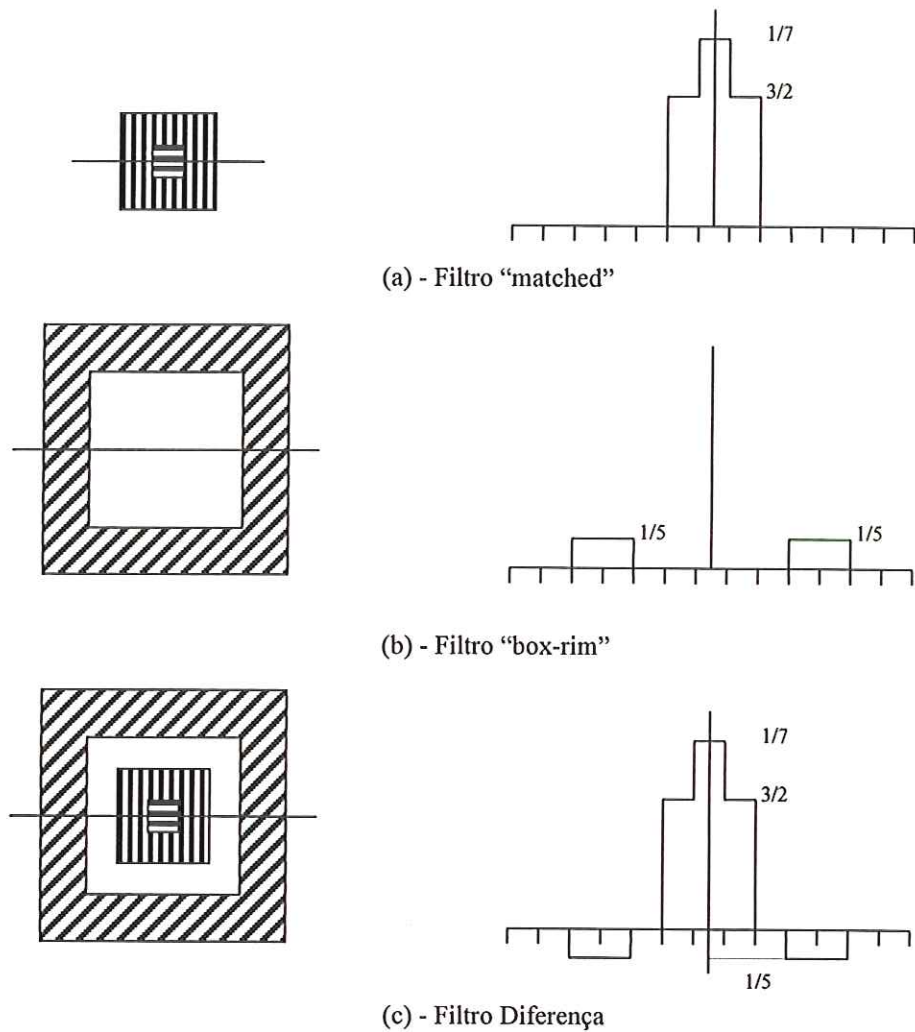


Figura 6.2 - Núcleos e perfis dos filtros usados pela técnica imagem-diferença - [CHAN-88A].

### 6.3.2.3 - "Thresholding" local adaptativo

A técnica de "thresholding" local adaptativo é baseada em estatísticas locais (média e desvio padrão) dos valores de cinza dos pixels contidos em uma região quadrada de  $m \times m$  pixels. O tamanho da região foi fixada em  $7 \times 7$  pixels após um ensaio com diferentes tamanhos de máscaras ( $7 \times 7$ ,  $11 \times 11$  e  $15 \times 15$ ). Para cada região da imagem é calculado o valor do limiar ("threshold") dado pela equação 6-1.

$$\text{limiar} = [1 - \min(T; \sigma/\mu)] * 255 \quad (6-1)$$

onde  $T$  é uma constante ajustada com valor entre 0 e 1.

Dessa forma, o pixel central da região analisada é ajustado para o nível de cinza máximo (255) se o seu valor de cinza é maior que o limiar, e para o valor mínimo (0) se o seu valor de cinza é menor que o limiar.

*ALGO-6.3.2c* : método “thresholding” local adaptativo

```
Início.  
ImagemAuxiliar = ImagemSegmentada.  
Ler parâmetro  $T$ .  
Repete até Fim da ImagemAuxiliar  
  Ler janela de 7x7 pixels da ImagemAuxiliar, PixelCentral (x,y).  
  Calcular  $\sigma$  e  $\mu$  para os pixels da janela.  
  Limiar =  $[1 - \min(T; \sigma / \mu)] * 255$ .  
  Se PixelCentral (x,y) da ImagemSegmentada > Limiar então  
    PixelCentral (x,y) da ImagemSegmentada = 255.  
  Senão  
    PixelCentral (x,y) da ImagemSegmentada = 0.  
  FimSe.  
  Avançar a janela 1 pixel adiante na ImagemAuxiliar.  
FimRepete  
Fim.
```

### 6.3.3 – Algoritmos dos principais atributos implementados

Para a caracterização e classificação das ROIs, foram implementados um total de 34 atributos: 13 de textura, descritos em [CHAN-97] e [HARALICK-73], 19 atributos caracterizando a variação entre as formas das microcalcificações e 2 indicando o número e a distribuição das microcalcificações dentro da região de interesse. A definição de cada um desses atributos encontra-se descrita no capítulo 3.

Os atributos de textura foram calculados a partir da média dos valores obtidos para cada matriz de co-ocorrência de níveis de cinza  $p(i,j)$  com orientações “ $\theta$ ” iguais a  $0^\circ, 45^\circ, 90^\circ$  e  $135^\circ$ , indicadas na Figura 6.3. Os atributos calculados não

mostraram variações significativas para valores de “d” variando entre 1 e 4. Dessa forma o valor da distância “d” foi fixada em 1. A matriz  $p(i,j)$  é do tipo simétrica, ou seja, a ocorrência dos pares de pixels  $(i,j)$  e  $(j,i)$  são considerados iguais. Além disso, a matriz final é normalizada através da divisão de cada elemento pelo número total dos pares de níveis de cinza, conforme [HARALICK-73].




Figura 6.3 - Definição das orientações 0°, 45°, 90° e 135° do pixel central, para o cálculo da matriz de co-ocorrência de níveis de cinza - [HARALICK-73].

Para a implementação de vários dos atributos de forma entre as microcalcificações, o perímetro das microcalcificações foi utilizado como uma medida básica. Neste trabalho, o perímetro foi calculado através do método da cadeia (“chain-code”), conforme descrito em [PARKER-94].

Todos os 34 atributos implementados e extraídos das imagens analisadas foram normalizados entre 0 e 1 usando a equação 6-2 :

$$\text{ValorNormalizado} = (\text{valor} - \text{min}) / (\text{max} - \text{min}) \quad (6-2)$$

Também, para efeito de simplificação da implementação dos classificadores e métodos de seleção, além de outras vantagens que esse modelo apresenta, assumiu-se o forma Gaussiana para as funções de distribuição de probabilidades dos atributos.

A seguir são apresentados os algoritmos das matrizes de co-ocorrência de níveis de cinza,  $p(i,j)$ , da diferença,  $p_{x-y}(k)$ , da soma,  $p_{x+y}(k)$ , e das distribuições marginais,  $p_x(i)$ ,  $p_y(j)$ , juntamente com as oito medidas mais discriminatórias obtidas no estágio de seleção de atributos, que são: entropia de  $p(i,j)$ , momento da diferença

inversa de  $p(i,j)$ , entropia de  $p_{x-y}(k)$ , entropia de  $p_{x+y}(k)$ , medidas de informação de correlação 1 e 2, fator número de microcalcificações e variância do segundo momento descritor de Hu ( $\phi_2$ ), calculada entre as microcalcificações da ROI..

No entanto, o vetor de medidas utilizado para a classificação foi formado somente pelas seis primeiras medidas descritas acima, uma vez que os demais atributos apresentaram valores de área de sobreposição entre as funções densidade de probabilidades maiores que 0,40.

ALGO-6.3.3a : cálculo da matriz de co-ocorrência de níveis de cinza,  $p(i,j)$

```
Início.  
NRO_TONS_CINZA = 256.  
Ler ângulo "θ" e distância "d".  
NX = Largura da ImagemNaoSegmentada.  
NY = Comprimento da ImagemNaoSegmentada.  
Crie e Inicialize  $p(NRO\_TONS\_CINZA, NRO\_TONS\_CINZA)$  com zeros.  
Se  $\theta = 0$  então  
    Dx = d.  Dy = 0.  
Senão  
    Se  $\theta = 45$  então  
        Dx = d.  Dy = -d.  
    Senão  
        Se  $\theta = 90$  então  
            Dx = 0.  Dy = d.  
        Senão  
            Dx = d.  Dy = d.  
    FimSe  
FimSe  
PrimeiroX = 0.  
PrimeiroY = max { -DY, 0 }.  
UltimoX = NX - DX.  
UltimoY = min { (NY-DY), NY }.  
Cont = 0.  
Para m = PrimeiroX até UltimoX-1  
    Para n = PrimeiroY até UltimoY-1  
        g1 = Pixel (m,n) da ImagemNaoSegmentada.  
        g2 = Pixel (m+DX, n+DY) da ImagemNaoSegmentada.  
         $p(g1,g2) = p(g1,g2) + 1$ .  
        Cont := Cont + 1.  
    FimPara  
FimPara  
Escala = 1.0/(2.0*Cont).  
Para m = 0 to NRO_TONS_CINZA-1 do  
    Para n = m to NRO_TONS_CINZA-1 do  
         $p(m,n) = p(m,n) + p(n,m)$ .  
         $p(m,n) = p(m,n)*Escala$ .  
         $p(n,m) = p(m,n)$ .  
    FimPara  
FimPara  
Fim
```



ALGO-6.3.3b : cálculo das matrizes  $p_{x+y}(i,j)$  ,  $p_{x-y}(i,j)$  ,  $p_x(i,j)$  ,  $p_y(i,j)$

Início.

NRO\_TONS\_CINZA = 256.

Criar e Inicializar  $p_{x+y}(NRO\_TONS\_CINZA, 1)$  e  $p_{x+y}(2*NRO\_TONS\_CINZA, 1)$  com zeros.

Criar e Inicializar  $p_x(NRO\_TONS\_CINZA, 1)$  e  $p_y(NRO\_TONS\_CINZA, 1)$  com zeros.

Para i = 0 até NRO\_TONS\_CINZA-1

Para j = 0 até NRO\_TONS\_CINZA-1

$p_{x+y}(abs(i-j), 0) = p_{x+y}(abs(i-j), 0) + p(i,j).$

$p_{x+y}(i+j, 0) = p_{x+y}(i+j, 0) + p(i,j).$

$p_x(i, 0) = p_x(i, 0) + p(i,j).$

FimPara

FimPara

Para j = 0 até NRO\_TONS\_CINZA-1

Para i = 0 até NRO\_TONS\_CINZA-1

$p_y(j, 0) = p_y(j, 0) + p(i,j).$

FimPara.

FimPara.

Fim.

ALGO-6.3.3c : entropia de  $p(i,j)$

Início.

NRO\_TONS\_CINZA = 256.

Entropia = 0.

Criar a matriz de co-ocorrência  $p(i,j)$  a partir da imagem Não-Segmentada.

Para i = 0 até NRO\_TONS\_CINZA-1

Para j = 0 até NRO\_TONS\_CINZA-1

Se  $p(i,j) > 0$  então

Entropia = Entropia -  $p(i,j) * \log_2(p(i,j))$ .

FimSe.

FimPara

FimPara

Fim.

*ALGO-6.3.3d* : momento da diferença inversa de  $p(i,j)$

Início.

NRO\_TONS\_CINZA = 256.

MomentoDifInv = 0.

Criar a matriz de co-ocorrência  $p(i,j)$  a partir da imagem Não-Segmentada.

Para  $i = 0$  até NRO\_TONS\_CINZA-1

Para  $j = 0$  até NRO\_TONS\_CINZA-1

MomentoDifInv = MomentoDifInv +  $p(i,j) / (1 + (i-j)^2)$ .

FimPara

FimPara

Fim.

*ALGO-6.3.3e* : entropia de  $p_{x,y}(i,j)$

Início.

NRO\_TONS\_CINZA = 256.

EntropiaDiferenca = 0.

Criar a matriz da diferença  $p_{x,y}(i,j)$  - vide ALGO-6.3.3b.

Para  $k = 0$  até NRO\_TONS\_CINZA-1

Se  $p_{x,y}(k,0) > 0$  então

EntropiaDiferenca = EntropiaDiferenca -  $p_{x,y}(k,0) * \log_2(p_{x,y}(k,0))$ .

FimSe.

FimPara.

Fim.

*ALGO-6.3.3f* : entropia de  $p_{x,y}(i,j)$

Início.

NRO\_TONS\_CINZA = 256.

EntropiaSoma = 0.

Criar a matriz da soma  $p_{x,y}(i,j)$  - vide ALGO-6.3.3b.

Para  $k = 0$  até NRO\_TONS\_CINZA-1

Se  $p_{x,y}(k,0) > 0$  então

EntropiaSoma = EntropiaSoma -  $p_{x,y}(k,0) * \log_2(p_{x,y}(k,0))$ .

FimSe

FimPara

Fim.

*ALGO-6.3.3g* : fator número de microcalcificações

Início.

Ler NroCalcificações.

FatorNroCalcif =  $1 - (0.75)^{\text{NroCalcificações}}$ .

Fim.

*ALGO-6.3.3h* : segundo momento descritor de Hu ( $\phi_2$ ) calculado para cada microcalcificação da ROI

Início.

Ler e extrair os pixels de cada microcalcificação da ImagemSegmentada.

Calcular momentos binários de segunda ordem  $m_{11}$ ,  $m_{20}$ ,  $m_{02}$  para a microcalcificação lida.

$\phi_2 = (m_{20} - m_{02})^2 + 4*(m_{11})^2$ .

Fim.

## 6.3.4 – Métodos utilizados para a seleção de atributos

Nesta seção são apresentados os dois métodos utilizados neste trabalho (erro de Bayes e distância de Jeffreys-Matusita) para a seleção dos melhores atributos usados na classificação.

### 6.3.4.1 - Erro de Bayes

Neste método, foram calculadas as áreas de sobreposição entre as funções densidades de probabilidades de forma exaustiva para todas as possíveis combinações entre pares de atributos dos 4 grupos de treinamento. A seguir, para três diferentes maneiras; análise dentro da classe benigna, análise dentro da classe maligna e análise entre as classes benigna e maligna, todos os valores de área foram organizados de forma crescente. Dos 34 atributos implementados, apenas 6 foram selecionados para compor o vetor de atributos. Todos os atributos selecionados possuem área de sobreposição menores que 0,35 (35%). A análise da sobreposição entre diferentes pares de atributos, dentro da própria classe, foi realizada para medir o grau de correlação entre os atributos. A Figura 6.4 é um representação

esquemática do cálculo do erro de Bayes.

$$Erro\ Bayes = \int_{-\infty}^T p(x | \omega_2)P(2) + \int_T^{+\infty} p(x | \omega_1)P(1) \quad (6-3)$$




Figura 6.4 - Erro de Bayes para um problema de decisão envolvendo um atributo e duas classes - [FUKUNAGA-90].

A seguir é apresentado o algoritmo descrevendo a metodologia empregada no cálculo da área de sobreposição de um par de atributos. No entanto, a metodologia se estende para quaisquer possíveis pares de atributos analisados.

ALGO-6.3.4a : Cálculo do Erro de Bayes

```
Início.  
Passo = 1E-4.  
ErroBayes = 0.  
  
Ler Atributo_A e Atributo_B  
Calcular  $\mu_A$ ,  $\mu_B$ .  
Calcular  $\sigma_A$ ,  $\sigma_B$ .  
  
MenorMedia =  $\mu_A$ .  
Se MenorMedia >  $\mu_B$  então  
    MenorMedia =  $\mu_B$ .  
FimSe.  
  
MaiorVariância =  $\sigma_A$ .  
Se MaiorVariância <  $\sigma_B$  então  
    MaiorVariância =  $\sigma_B$ .  
FimSe.  
  
Início = ( MenorMedia - 3*MaiorVariância ).  
Fim = (MaiorMedia + 3*MaiorVariância ).  
Para i = Início, incremento = Passo, até Fim  
    Calcular  $f(i, \mu_A, \sigma_A)$  e  $f(i, \mu_B, \sigma_B)$ .  
    Se  $f(i, \mu_A, \sigma_A) < f(i, \mu_B, \sigma_B)$  então  
        ErroBayes = ErroBayes + Passo*  $f(i, \mu_A, \sigma_A)$ .  
    Senão  
        ErroBayes = ErroBayes + Passo*  $f(i, \mu_B, \sigma_B)$ .  
    FimSe.  
FimPara.  
Fim.  
  
Onde  $\mu_A, \sigma_A$  -  $\mu_B, \sigma_B$  são os valores de média e variância, respectivamente, calculados para os atributos A e B.  
 $f(i, \mu_A, \sigma_A)$  e  $f(i, \mu_B, \sigma_B)$  são os valores das funções Gaussianas, calculados no ponto  $i$ , para os atributos A e B.
```

#### 6.3.4.2 - Distância "Jeffries-Matusita"

A distância de Jeffries-Matusita é uma técnica utilizada para medir a separabilidade entre duas distribuições de probabilidades. Nesse trabalho, essa medida de distância foi usada para avaliar o subgrupo de atributos determinado pelo erro de Bayes.

A distância de Jeffries-Matusita ou distância JM, para o caso de duas classes envolvidas,  $\omega_1$  e  $\omega_2$ , é calculada da seguinte forma:

$$J_{ij} = \left\{ \int \left[ \sqrt{p(\mathbf{x} | \omega_i)} - \sqrt{p(\mathbf{x} | \omega_j)} \right]^2 d\mathbf{x} \right\}^{1/2} \quad (6-2)$$

e no caso onde  $p(\mathbf{x}|\omega_i)$  e  $p(\mathbf{x}|\omega_j)$  são descritas por funções Gaussianas a equação acima assume a forma:

$$J_{ij} = \sqrt{2 \cdot (1 - e^{-\alpha})} \quad \text{onde} \quad (6-3)$$

$$\alpha = \frac{1}{8} [\mu_i - \mu_j]^T \left[ \frac{\Sigma_i + \Sigma_j}{2} \right]^{-1} [\mu_i - \mu_j] + \frac{1}{2} \log_e \left[ \frac{|\Sigma_i| + |\Sigma_j|}{2 \sqrt{|\Sigma_i| |\Sigma_j|}} \right] \quad (6-4)$$

$\mathbf{x}$  representa um vetor de atributos.

$p(\mathbf{x}|\omega_i)$  e  $p(\mathbf{x}|\omega_j)$  são as funções densidades de probabilidades para as classes  $i$  e  $j$ .

$\mu_i$ ,  $\mu_j$  e  $\Sigma_i$ ,  $\Sigma_j$  são os vetores de médias e as matrizes de covariância para as classes  $i$  e  $j$ , respectivamente.

Quando as classes estão totalmente separadas,  $\alpha$  tende ao infinito e portanto  $J_{ij}$  tende para  $\sqrt{2}$  (aproximadamente 1.414). Por outro lado, quando as classes estão totalmente sobrepostas  $\alpha=0$  e portanto  $J_{ij} = 0$ . O algoritmo ALGO-6.3.4b descreve o cálculo da distância JM.

ALGO-6.3.4b : Cálculo da distância JM

Início.

Ler  $\mathbf{x}_B$ ,  $\mathbf{x}_M$ . // leitura dos vetores de atributos das classes benigna e maligna, respectivamente.

Calcular  $\mu_B$ ,  $\mu_M$ . // calcula vetores de médias das classes benigna e maligna.

Calcular  $\Sigma_A$ ,  $\Sigma_B$ . // calcula matrizes de covariância das classes benigna e maligna.

MatAux1 =  $\mu_B - \mu_M$ .

MatAux2 =  $0.5 * (\Sigma_A + \Sigma_B)$ .

MatAux3 =  $(\text{MatAux1})^T * (\text{MatAux2})^{-1}$ . //  $( )^T$  - operador matriz composta;  $( )^{-1}$  - operador matriz inversa

MatAux3 =  $\text{MatAux3} * \text{MatAux1}$ .

Alpha =  $(1/8) * \text{MatAux3} + (1/2) * \ln( |\text{MatAux2}| / \sqrt{|\Sigma_A| |\Sigma_B|} )$ . //  $| |$  - operador determinante

DistanciaJM =  $\sqrt{2 * (1.0 - \exp(-Alpha))}$ .

Fim.

### 6.3.5 – Métodos de Classificação implementados

Nesta seção são descritas as metodologias empregadas na implementação dos três métodos de classificação usados neste trabalho e seus respectivos algoritmos.

#### 6.3.5.1 - Classificadores Bayesianos

Como descrito no capítulo 4, a regra de decisão de Bayes é uma técnica paramétrica do tipo “plug-in”, ou seja, os parâmetros do classificador são estimados a partir de alguma técnica específica, neste caso por máxima verossimilhança, e injetados nas densidades de probabilidades de cada classe. Neste trabalho, como foi assumido o modelo Gaussiano para as fdps de cada classe, os parâmetros estimados foram: vetores de médias e matrizes de covariância das classes maligna e benigna. Foram implementados os classificadores quadrático e linear, sendo que neste último caso, onde a borda de decisão é dada por uma função linear, o classificador foi implementado usando a média entre as matrizes de covariâncias de cada classe, ou seja,  $\Sigma = \frac{(\Sigma_1 + \Sigma_2)}{2}$ .

Os parâmetros foram estimados usando sempre as amostras rotuladas dos grupos de treinamento, para a técnica de validação: “leave-k-out”. Esse procedimento foi adotado para evitar que amostras usadas para avaliar o desempenho do classificador aparecessem também no grupo de treinamento. Para avaliar o comportamento dos classificadores, em diferentes situações, os testes de desempenho foram realizados a partir das regras de Bayes para mínimo risco e máxima probabilidade *a posteriori*, com e sem rejeição. As probabilidades *a priori*, custos do falso-positivo e falso-negativo e limiar de rejeição foram alterados para simular diferentes situações (sistema com mínima e máxima sensibilidade). O custo do acerto foi considerado igual a zero.

O algoritmo ALGO-6.35a, descreve de maneira geral as regras de Bayes implementadas.

ALGO-6.3.5a : Classificador usando a Regra de Bayes

Início.

Estimar parâmetros ( $\mu_B$ ,  $\mu_M$ ,  $\Sigma_B$ ,  $\Sigma_M$ ) a partir das amostras de treinamento.

Ler informações *a priori* ( $P(\omega_B)$ ,  $P(\omega_M)$ , Custo(FP), Custo(FN), LimiarRejeição ).

Ler vetor de atributos  $x$  da amostra desconhecida (amostra a ser classificada).

Selecionar o tipo de classificador (linear ou quadrático).

Se TipoClassificador = 'linear' então

$$\Sigma = (\Sigma_B + \Sigma_M) / 2.$$

$$p_B(x) = f(x, \mu_B, \Sigma). \quad // \text{ valor da fdp Gaussiana multivarida da classes benigna no ponto } x$$

$$p_M(x) = f(x, \mu_M, \Sigma). \quad // \text{ valor da fdp Gaussiana multivarida da classes benigna no ponto } x$$

Senão

$$p_B(x) = f(x, \mu_B, \Sigma_B).$$

$$p_M(x) = f(x, \mu_M, \Sigma_M).$$

FimSe.

$$\text{ProbPosterioriB} = p_B(x) * P(\omega_B) / (p_B(x) * P(\omega_B) + p_M(x) * P(\omega_M)).$$

$$\text{ProbPosterioriM} = p_M(x) * P(\omega_M) / (p_B(x) * P(\omega_B) + p_M(x) * P(\omega_M)).$$

Se Custo(FP) = 0 e Custo(FN) = 0 então

Se max {ProbPosterioriB, ProbPosterioriM} <= LimiarRejeição então

Resultado = 'NÃO FOI POSSÍVEL CLASSIFICAR AMOSTRA – REJEIÇÃO'.

Senão

Se ProbPosterioriB > ProbPosterioriM então

Resultado = 'SUSPEITA : LESÃO BENIGNA'.

Senão

Resultado = 'SUSPEITA : LESÃO MALIGNA'.

FimSe.

FimSe.

Senão

$$\text{RiscoBenignidade} = \text{Custo(FN)} * \text{ProbPosterioriM}.$$

$$\text{RiscoMalignidade} = \text{Custo(FP)} * \text{ProbPosterioriB}.$$

Se max {RiscoBenignidade, RiscoMalignidade} >= LimiarRejeição então

Resultado = 'NÃO FOI POSSÍVEL CLASSIFICAR AMOSTRA – REJEIÇÃO'.

Senão

Se RiscoBenignidade < RiscoMalignidade então

Resultado = 'SUSPEITA : LESÃO BENIGNA'.

Senão

Resultado = 'SUSPEITA : LESÃO MALIGNA'.

FimSe.

FimSe.

FimSe.

Fim.





### 6.3.5.2 - Método K-NN

O método K-NN utilizado neste trabalho, descrito na seção 4.2.2 do capítulo 4, foi implementado usando dois limiares  $M_B$  e  $M_M$  que permitem ajustar a sensibilidade do sistema de classificação. O limiar  $M_B$  é o número mínimo de votos benignos, dentro dos K vizinhos mais próximos, para que uma determinada amostra seja classificada como benigna. O mesmo ocorre com o limiar  $M_M$  que corresponde ao número mínimo de votos para a classe maligna. O uso destes limiares permitem criar uma região de rejeição, onde é melhor não classificar determinada amostra devido ao baixo grau de confiança na decisão.

Como medida de distância entre os vetores das amostras, foi utilizada a distância Euclidiana. Para a implementação deste método foi utilizada uma estrutura, descrita abaixo, contendo as variáveis “Distancia” e “Classe”, as quais armazenaram, respectivamente, o valor da distância entre a amostra desconhecida e uma amostra de treinamento, e o nome da classe a qual a amostra rotulada pertence.

O algoritmo ALGO-6.3.5b, descreve o classificador implementado usando o método K-NN.

```
TestruturaDistancia = record
  Distancia      : Extended;
  Classe         : String;
end;
```

ALGO-6.3.5b : Classificador usando o Método K-NN

```
Inicio.
ContMaligna = 0.
ContBenigna = 0.
Ler NroAmostrasB e NroAmostrasM.
Criar vetor VetDistancia ( NroAmostrasB + NroAmostrasM ) do tipo TestruturaDistancia.
Ler parâmetros: K, MB, MM.
Ler vetor x de atributos.

Para i = 0 até NroAmostrasB - 1
    VetDistancias(i) → Distancia = CalcDistEuclidiana ( VetAmostraB(i), x ).
    VetDistancias(i) → Classe = 'BENIGNA'.
FimPara.

Para j = 0 até NroAmostrasM - 1 até
    VetDistancias(j + NroAmostrasB) → Distancia = CalcDistEuclidiana ( VetAmostraM(j), x ).
    VetDistancias(j + NroAmostrasB) → Classe = 'MALIGNA'.
FimPara.

Ordenar VetorDistancias. // ordena vetor em ordem crescente de distâncias usando o método da bolha.
Para i=0 até K-1
    Se VetorDistancias(i) → Classe = 'MALIGNA' então
        ContMaligna = ContMaligna + 1.
    Senão
        ContBenigna = ContBenigna + 1.
    FimSe.
FimPara.

Se ContMaligna >= MM então
    Resultado = 'SUSPEITA : LESÃO MALIGNA'.
Senão
    Se ContBenigna >= MB então
        Resultado = 'SUSPEITA : LESÃO BENIGNA'.
    Senão
        Resultado = 'NÃO FOI POSSÍVEL CLASSIFICAR AMOSTRA - REJEIÇÃO'.
    FimSe.
FimSe.
Fim.
```

### 6.3.5.3 - Redes Neurais Artificiais

Várias topologias da rede neural artificial MLP (perceptron multi-

camadas) foram analisadas neste trabalho para diferentes grupos de treinamento e teste. A verificação da melhor topologia da rede foi realizada através da alteração do número de camadas escondidas e número de neurônios nestas camadas.

O primeiro ensaio foi realizado para uma rede completamente conectada contendo uma camada intermediária, e com número de neurônios iguais à: 4,6,8,10,12 e 14.

No segundo ensaio foi introduzida uma segunda camada intermediária com o número de neurônios igual a metade do número existente na primeira camada. O número de neurônios para ambas as camadas foram variados concomitantemente de duas unidade entre 4 e 14, sempre mantendo a relação: neurônios da 2ª camada igual a metade do número de neurônios da 1ª camada.

Em ambos os ensaios, foram utilizadas as funções de ativação do tipo logística ou "sigmoid" e número de neurônios na camada de saída igual a 1.

As redes foram implementadas usando o "Matlab - Neural Network Toolbox versão 2.0.3". Para treinamento das redes foi utilizado o algoritmo de "Levenberg-Marquardt", que é uma versão modificada do algoritmo "backpropagation". O algoritmo "backpropagation" é baseado no gradiente descendente que é simplesmente uma técnica onde os parâmetros, pesos e "bias", são alterados (movidos) em direção contrária ao gradiente de erro. Em cada passo, no sentido descendente da superfície de erro, resulta em menores erros até que um erro mínimo seja alcançado. O uso de momento muda este procedimento apenas tornando as mudanças proporcionais a média de execução do gradiente. O algoritmo de "Levenberg-Marquardt" alcança melhor desempenho através do uso do método de aproximação de Newton. Esta técnica, segundo Howard Demuth e Mark Beale [DEMUTH-94], é mais poderosa que o gradiente descendente, mas requer mais memória do computador para a sua execução.

A regra de atualização dos pesos no método de "Levenberg-Marquardt" é dada por:

$$\Delta W = (J^T J + \mu I)^{-1} J^T e$$

onde  $J$  é a matriz Jacobiana de derivadas de cada erro para cada peso,  $\mu$  é um escalar, e  $e$  é um vetor de erro. Se o escalar  $\mu$  é muito grande, a expressão acima aproxima-

se do gradiente descendente, enquanto que, se ele for pequeno a expressão torna-se o método de Gauss-Newton. O método de Gauss-Newton próximo de um erro mínimo é rápido e mais exato, portanto o objetivo é deslocar para a direção desse método o mais rápido possível. Dessa forma  $\mu$  diminui a cada passo com sucesso e aumenta apenas quando um passo incrementa o valor do erro.

Os parâmetros utilizados para o treinamento das redes são descritos na Tabela 6.2.

Número máximo de interações	Soma do erro quadrático desejado	mínimo gradiente de erro	valor inicial para $\mu$	multiplicador para incrementar $\mu$	multiplicador para decrementar $\mu$	máximo valor para $\mu$
5000	0.001	0.0001	0.01	10	0.1	1E10

Tabela 6.2 - principais parâmetros usados no treinamento das RNAs.

O treinamento inicia-se através do ajuste dos parâmetros do algoritmo e também da inicialização aleatória dos pesos e "bias" da rede, e continua até que um dos seguintes eventos ocorra: o erro desejado seja alcançado, o mínimo gradiente de erro ocorra, o máximo valor de  $\mu$  ocorra ou o número máximo de interações (épocas) tenha terminado.

O algoritmo ALGO-6.3.5c, descreve de forma simplificada as etapas de treinamento e teste das redes MLPs implementadas.

TREINAMENTO.

Início.

Iniciar todas as conexões com valores aleatórios.

Ler parâmetros da rede. - vide Tabela 6.2

Erro = 0.

$\epsilon$  = Erro Desejado.

Repete Até Erro <  $\epsilon$

    Erro = 0.

    Para cada camada  $k = 1$  até  $N$

        Para cada neurônio  $J = 1$  até  $M_k$

            Calcular a saída  $y_{jk}$ .

        Se ( $k = M$ ) e ( $d_j \neq y_{Nj}$ ) então

            Erro = Erro +  $0.5 * (d_j - y_{jk})$ .

        FimSe.

    FimPara.

FimPara.

Se Erro >  $\epsilon$  então

    Para cada camada  $k = 1$  até  $N$

        Para cada neurônio  $J = 1$  até  $M_k$

            Atualizar pesos.

        FimPara.

    FimPara.

FimSe.

FimRepete.

Fim.

TESTE.

Início.

Iniciar os pesos da rede com os valores encontrados na etapa de treinamento.

Apresentar vetor de atributos  $x$  a ser reconhecido.

Para cada camada  $k = 1$  até  $N$

    Para cada neurônio  $J = 1$  até  $M_k$

        Calcular a saída  $y_{jk}$ .

    FimPara.

FimPara.

Comparar saída  $y_{Nj}$  com  $d_c$  (saída desejada) para cada classe  $c$ .

Classificar padrão como pertencente a classe cuja saída desejada é mais próxima da saída produzida.

Fim.

## 6.4 – Metodologia utilizada na análise de resultados

O objetivo desta seção é dar uma visão geral sobre os tópicos da teoria de detecção de sinal e curvas ROC (“receiver operating characteristic analysis”), os quais formam as bases dos métodos usados para testar o desempenho de sistemas de detecção e classificação automáticos.

### 6.4.1 - Teoria da detecção de sinal

A teoria de detecção de sinal é baseada na idéia que para qualquer sinal sempre existirá um fundo ruidoso que varia aleatoriamente sobre um valor médio. Quando um estímulo está presente, a atividade que ele cria no sistema de imageamento é adicionada ao ruído existente naquele momento. Este ruído pode estar dentro do próprio sistema ou fazer parte do padrão de entrada. A tarefa do observador (ou sistema automático) é determinar se o nível de atividade no sistema é devido apenas ao ruído ou do resultado de um estímulo adicionado ao ruído.

De acordo com A.Li Evans [EVANS-81], em sua forma mais simples, a tarefa de diagnosticar consiste na apresentação de imagens, contendo ou não uma anormalidade associada a um observador que deve responder se existe ou não uma anormalidade presente. Se uma imagem contém uma anormalidade, a entrada para o sistema de imageamento contém um sinal 's'. Entretanto, a imagem pode não conter uma anormalidade e, a medida que o diagnóstico é concedido, ela pode ser considerada como um ruído, sinal 'n'. Quando a imagem é apresentada ao observador, ele pode responder 'S' (sinal), se achar que uma anormalidade está presente, ou 'N' (ruído) se achar que não. Dessa forma, a avaliação de um sistema pode ser realizada usando um grande número de imagens contendo os seus respectivos diagnósticos de biópsia conhecidos. O experimento consiste em mostrar a um observador cada uma das imagens e gravar a sua resposta – ‘S’ ou ‘N’. Quando a

transferência de informação é completa o observador responde ‘S’ cada vez que a imagem contém o sinal ‘s’, e ‘N’ quando a imagem apresenta ‘n’, isto é:

$$\begin{aligned} p(S | s) &= 1 & p(N | n) &= 1 \\ p(S | n) &= 0 & p(N | s) &= 0 \end{aligned}$$

onde  $p(S | s)$ , a qual se lê “a probabilidade de acontecer S dado s”, é a probabilidade condicional da resposta S quando a entrada para o sistema de imageamento é s.

Quando o sistema não transfere a informação perfeitamente essas probabilidades condicionais são diferentes da unidade (valores fracionários).

### 6.4.2 - Matriz de estímulo-resposta

A tabela 6.3, mostra uma matriz de estímulo-resposta para um sistema de imageamento. Cada uma das células contém probabilidades condicionais as quais são freqüentemente citadas na avaliação de testes de diagnóstico. Se o sistema é bom na transferência da informação, o observador freqüentemente responderá S quando o sinal de entrada é ‘s’, isto é  $p(S | s)$  será próximo da unidade. A taxa de positivo-verdadeiros,  $p(S | s)$ , é chamada de sensibilidade do sistema.

Se o observador responde N quando a imagem contém um sinal ‘s’, o observador comete um erro, dando uma resposta negativa quando o correto seria dar uma resposta positiva. O valor de  $p(N | s)$  é chamado de taxa de falso-negativos.

		Resposta: Sinal presente ?	
		“Sim”	“Não”
Estímulo	Presente	Acerto (Verdadeiro-Positivo)	Erro (Falso-Negativo)
	Ausente	Falso Alarme (Falso-Positivo)	Correta Negação (Verdadeiro- Negativo)

Tabela 6.3 - Possibilidades de respostas em um experimento de teoria de detecção de sinal.

É desejável que o observador responda N quando o sinal 's' estiver ausente na imagem. A especificidade de um teste de diagnóstico é a fração das imagens que são corretamente identificadas como não tendo sinal, ou  $p(N | n)$ .

Finalmente, o observador pode erroneamente dizer que um sinal 's' está presente quando de fato a imagem não contém este sinal. Isto é chamado de resposta falso-positiva, e a probabilidade de ocorrência desse erro,  $p(S | n)$ , é chamada de taxa de falso-positivos.

Um sistema de imageamento ideal possui sensibilidade e especificidade iguais a unidade e taxas de falso-positivos e falso-negativos iguais a zero. Um bom sistema de diagnóstico terá alta sensibilidade e alta especificidade com baixas taxas de falso-positivos e falso-negativos..

### 6.4.3 - Curva característica de operação do receptor (curva ROC)

Uma vez mostrada uma imagem para um observador, o mesmo deve responder S ou N. Dessa forma a matriz estímulo-resposta possui dois graus de liberdade, pois:

$$\begin{aligned} p(N | n) + p(S | n) &= 1 & \text{e} \\ p(N | s) + p(S | s) &= 1 \end{aligned}$$

As informações das células da matriz podem ser representadas por um ponto A num gráfico bidimensional. As coordenadas de A são convencionalmente dadas por  $p(S | s)$  e  $p(S | n)$ , ou seja, as taxas de positivo-verdadeiros e falso-positivos, (ver Figura 6.5).

O ponto A na Figura 6.5 mostra o comportamento do observador em



dar uma resposta (realizar o diagnóstico) caso fossem apresentadas a ele uma série de imagens nas mesmas condições experimentais. A resposta do observador pode ser modificada a medida em que se altera o critério de decisão (mais rigoroso, ou menos rigoroso) ou as condições experimentais do problema, ponto B.

Dessa forma pode-se gerar uma curva através de sucessivas mudanças nos critérios do observador. Essa curva é chamada curva característica de operação do receptor ou curva ROC. Qualquer ponto dessa curva descreve um critério do observador para distinguir entre o que ele classifica como sinal ou ruído. Então, a partir dessa curva é possível encontrar o critério o qual apresenta o maior número de acertos e o menor número de erros para o diagnóstico.




Figura 6.5 - Informações de uma matriz de estímulo-resposta, expressas em forma gráfica usando  $p(S | s)$  e  $p(S | n)$  como coordenadas dos pontos A e B.

#### 6.4.4 - A geração de curvas ROC na prática

A geração da curva ROC é realizada através da determinação de pontos, representados pelas taxas de falso-positivos e verdadeiro-positivos,

calculados sobre um grande número de amostras rotuladas alterando-se um dos seguintes parâmetros: (a) probabilidades *a priori* de ocorrência do sinal, (b) limiar de decisão, (c) custos envolvidos na tomada de decisão.

### 6.4.5 - Comparação de curvas ROC

Nas seções anteriores as curvas ROC foram discutidas para um experimento contendo uma relação sinal-ruído fixa. O que acontece quando essa relação aumenta? Obviamente, como o sinal torna-se mais forte a decisão torna-se mais fácil e a curva ROC se move em direção ao canto superior esquerdo do gráfico. Para as duas curvas mostradas na Figura 6.6, as respostas obtidas nas condições experimentais que produzem a curva A são melhores que aquelas que produzem a curva B. Neste caso, escolher entre as condições experimentais de A e as de B não é difícil porque as taxas de positivo-verdadeiros são sempre maiores para a curva A para todos os valores da taxa de falso-positivo.

Entretanto, se as curvas ROC se interceptam conforme Figura 6.7, a posição do ponto de operação do observador determinará qual a curva que apresenta a maior taxa de positivo-verdadeiros e dessa forma qual a condição experimental mais favorável.

### 6.4.6 - Área sob a curva ROC

No primeiro momento, a área sob a curva ROC pode parecer ser uma medida do quão bem o sinal é detectável. Se  $p(S | s)$  é próximo da unidade para muitos valores de  $p(S | n)$ , a área sob a curva aproxima-se da unidade e o observador está próximo da decisão correta. Se o sinal não é distinto do ruído, o observador classificará a imagem como N ou S de forma aleatória e a curva ROC estará próxima a diagonal positiva do gráfico. A área sob a curva ROC neste caso será próxima de

0,5, representando a probabilidade do observador responder corretamente.

No entanto, se as curvas se interceptam, a curva tendo a menor área pode apresentar a maior taxa de positivo-verdadeiros,  $p(S | s)$ , para uma dada taxa de falso-positivos,  $p(S | n)$ , e portanto nesse caso, a área sob a curva não mede de forma real a detecção do sinal.




Figura 6.6 - Exemplos de curvas ROC quando a relação sinal ruído é aumentada.




Figura 6.7 - Exemplo de curvas ROC interceptadas.

# Capítulo 7

## Descrição e Análise dos Resultados Obtidos

### 7.1 – Software de Gerenciamento da Base de Dados

O software de gerenciamento da base de dados é composto por 4 seções principais: Identificação, Antecedentes, História da moléstia atual e alterações em exames e Outras Informações, ilustradas nas Figuras 7.1, 7.2, 7.3 e 7.4, respectivamente. O programa permite a realização de filtros sobre os dados armazenados através de chaves previamente definidas, as quais selecionam os casos contendo: Nódulos, Microcalcificações, Nódulo + microcalcificações, Densidade Assimétrica, Densidade Assimétrica + microcalcificações, Lesões espiculadas e Normais. Também é permitida a pesquisa por nome da paciente e por número de registro.

Caso	Nome	RG	Endereço	Bairro

Figura 7.1 - Tela de identificação da paciente: contém informações que facilitam a localização de outras informações clínicas dentro do arquivo do Hospital.

Figura 7.2 - Tela de antecedentes: contém informações dos antecedentes familiares, menstruais, pessoais e obstétricos.

Figura 7.3 - Tela da história da moléstia atual e alterações em exames: contém informações dos problemas atuais e laudos de alterações mamográficas e ecográficas.

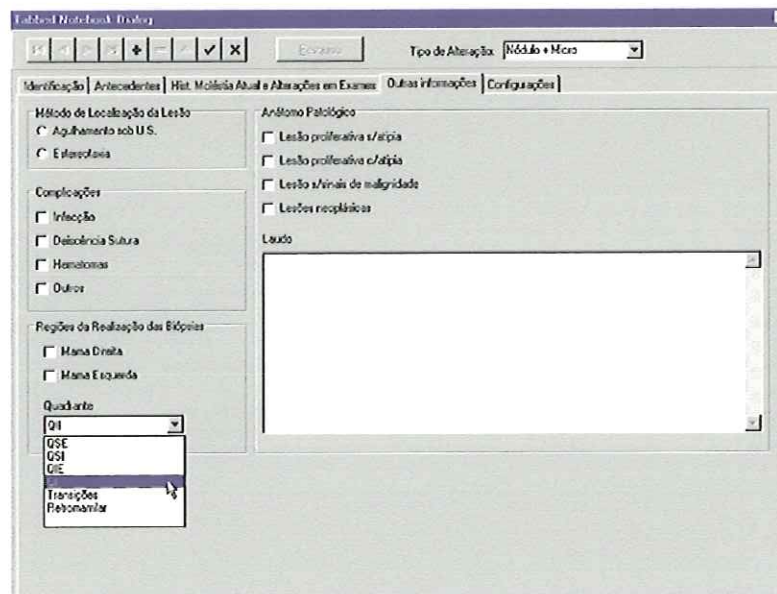


Figura 7.4 - Tela contendo informações diversas e o laudo geral da paciente.

Na tela da história da moléstia atual, Figura 7.3, é possível associar imagens mamográficas (vistas crânio caudal, oblíqua e magnificada) e ecográficas às informações clínicas. A associação da imagem é realizada registrando-se a localização e o nome da imagem em uma tabela de dados do tipo “Paradox”. No item “configurações”, é possível indicar um nome de um programa de visualização de imagens, por exemplo “Paint Shop Pro”, “Paint Brush”, etc., para que a imagem possa ser visualizada e manipulada. Dessa forma, quando o botão de visualização da imagem é acionado, o software de visualização é executado e automaticamente abre a imagem indicada na tabela “Paradox”.

As informações armazenadas na base de dados permitem determinar com exatidão a localização do(s) agrupamento(s) de microcalcificações. Para futuros trabalhos, essas informações poderão também servir como atributos para a classificação.

## 7.2 – Segmentação

O método de segmentação utilizado é composto por três técnicas básicas: método de "stretching" (ou linearização do histograma), imagem-diferença e um método de "thresholding" adaptativo.

A linearização do histograma foi aplicada a cada ROI analisada tanto para efeito de normalização dos valores de níveis de cinza (fato importante na análise de textura), como para aumentar o seu contraste. As imagens da Figura 7.5 (a),(b),(c) e (d) ilustram dois exemplos de aplicação dessa técnica.




Figura 7.5 - (a)-(d) Imagens antes ( (a) e (c) ) e depois ( (b) e (d) ) da aplicação do método "stretching". Todas as imagens possuem aumento de 6 vezes em relação ao tamanho original. Os valores de níveis de cinza mínimo e máximo para a imagem (a) são 28 e 85, e para a imagem (b) são 0 e 255.

É importante notar que, se o histograma tiver pelo menos um valor de nível de cinza em cada extremo do histograma (níveis 0 e 255) a imagem não será alterada, vide Figura 7.5 (c) e (d).

Após a linearização do histograma, a imagem é submetida à técnica imagem-diferença. A aplicação deste método realça as microcalcificações através da eliminação das estruturas de fundo da imagem. As Figura 7.6 e 7.7, ilustram dois exemplos de resultados da aplicação dessa técnica, sem e com a linearização prévia do histograma, respectivamente.




Figura 7.6 - Estágios do método de segmentação (a) Imagem original da ROI (b) Imagem após a aplicação da técnica imagem-diferença.





Figura 7.7 - Estágios do método de segmentação (a) Imagem original da ROI (b) Imagem após a técnica de "stretching" (c) Imagem após a aplicação da técnica imagem-diferença.

A linearização do histograma, apesar de ser um método muito simples, aumenta de forma considerável o contraste entre as microcalcificações e as estruturas



de fundo, deixando-as muito mais evidentes na imagem final, vide Figuras 7.6 (b) e 7.7 (c) para efeito de comparação.

Ao final da aplicação da técnica imagem-diferença, a imagem resultante ainda não se encontra totalmente binarizada. Para a binarização dessa imagem foi implementado um método de "thresholding" adaptativo, que utiliza estatísticas locais da imagem (média e desvio padrão) a fim de manter apenas os pixels pertencentes as microcalcificações. Esse processo é executado através da análise de regiões fixas de tamanho  $m \times m$  pixels. Não houve nenhuma modificação significativa em termos de sinais falso-positivos na imagem final após a variação do tamanho das máscaras. Entretanto, o valor do limiar constante (  $T$  ), indicado na equação 6.1 do capítulo 6, exerce grande influência no resultado final. A variação desse limiar foi estudada para um grupo de 10 diferentes imagens e o melhor resultado foi obtido, por inspeção visual de médicos especialistas, para um valor igual a 0,35. As Figuras 7.8 (b),(c) e (d), ilustram exemplos de resultados obtidos pelo método de "thresholding" adaptativo para diferentes valores do limiar  $T$ .



**Figura 7.8 - Thresholding Adaptativo usando região de 7x7 pixels (a) Imagem original (b) Imagem resultante com  $T = 0,35$  (c) Imagem resultante com  $T = 0,50$  (d) Imagem resultante para  $T = 0,70$ .**

A seguir, as figuras 7.9, 7.10 e 7.11 ilustram as telas de apresentação de cada etapa do método de segmentação. A ROI processada pode ser visualizada durante o todo o decorrer do processo. Todo o processamento da imagem é realizado sobre uma cópia da imagem original de forma a preservá-la.

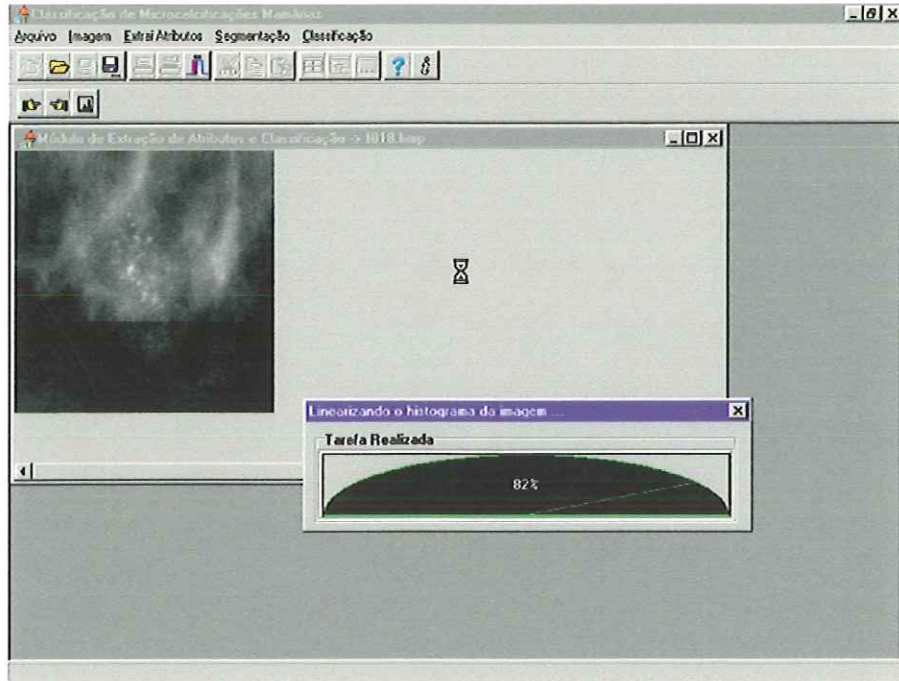


Figura 7.9 - Tela de saída do sistema segmentação: linearização do histograma da imagem.

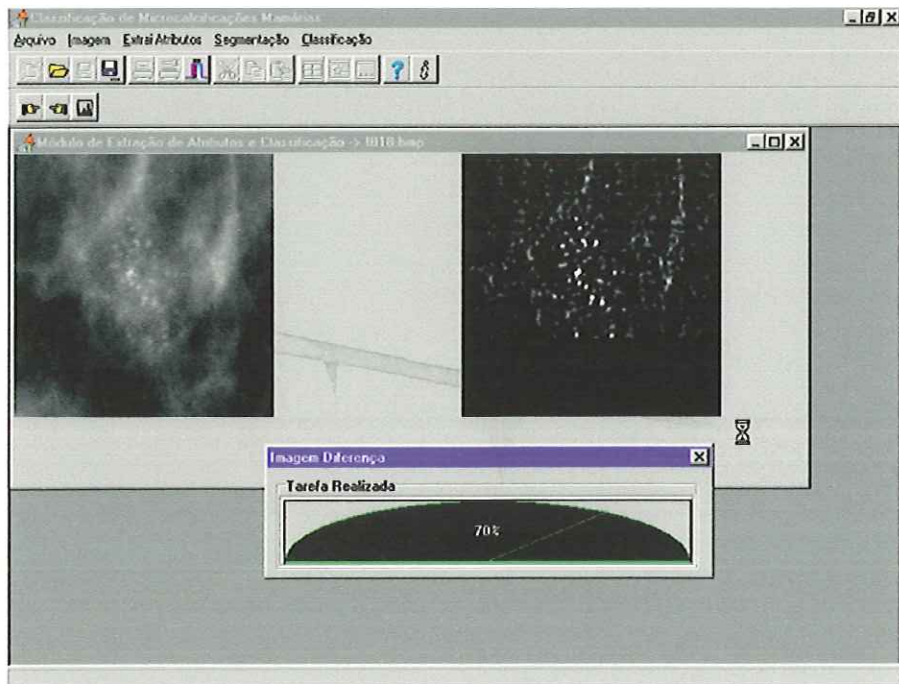


Figura 7.10 - Tela de saída do sistema de segmentação – técnica imagem-diferença.

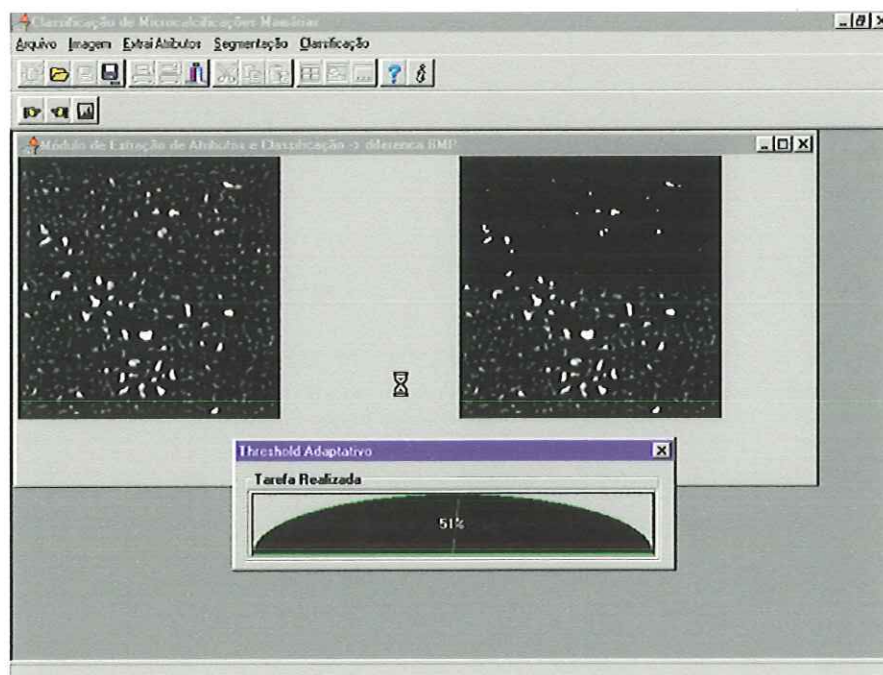


Figura 7.11 - Tela de saída do sistema: "thresholding" adaptativo.

### 7.3 – Seleção de atributos

Nesta seção são ilustrados os 8 melhores atributos selecionados de um total de 34 analisados através do erro de Bayes. Desses oito, apenas os seis primeiros foram usados para compor o vetor de atributos utilizado no estágio de classificação. As Figuras 7.12 e 7.13 ilustram os atributos analisados neste trabalho. Na Tabela 7.1 são apresentados os resultados médios da seleção através do erro de Bayes calculados sobre os 4 grupos de treinamento, para cada atributo das classes benigna e maligna. Também foram calculadas as correlações de todos os pares de atributos dentro da própria classe.

A distância de Jeffries-Matusita foi usada para investigar o comportamento do subgrupo de atributos, selecionado através do erro de Bayes, com relação ao grau de separabilidade entre as classes. A medida JM média alcançada para os grupos de treinamento pelo conjunto dos seis atributos foi igual a 1,3372. Esse valor médio é satisfatório uma vez que a curva de máxima separabilidade é assintótica com máximo valor tendendo a  $\sqrt{2}$ , ou aproximadamente 1,4142.

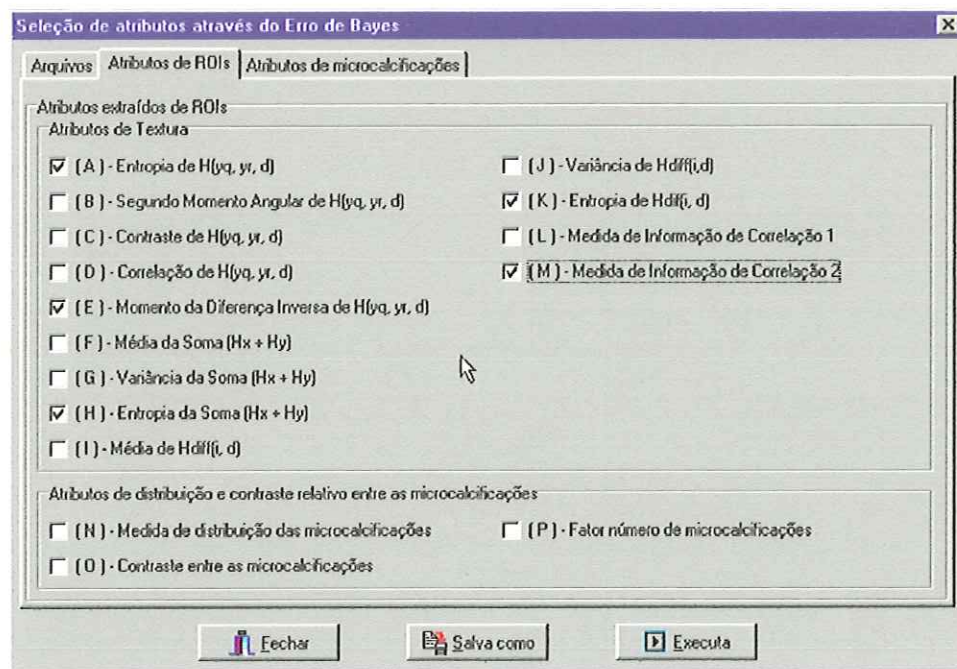


Figura 7.12 - Tela do sistema com a relação de atributos de textura e de contraste e distribuição das microcalcificações.

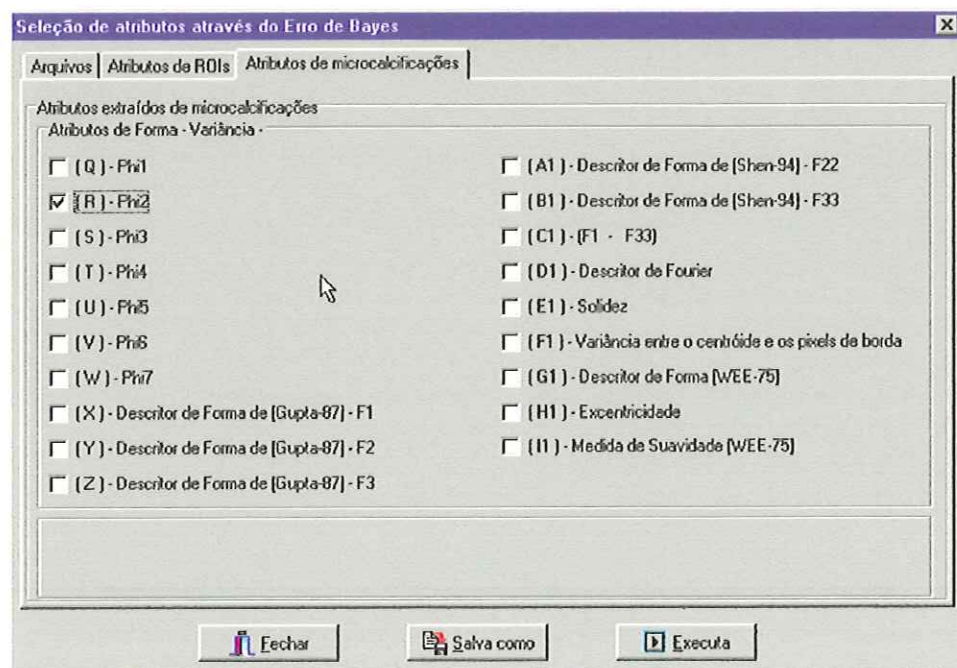


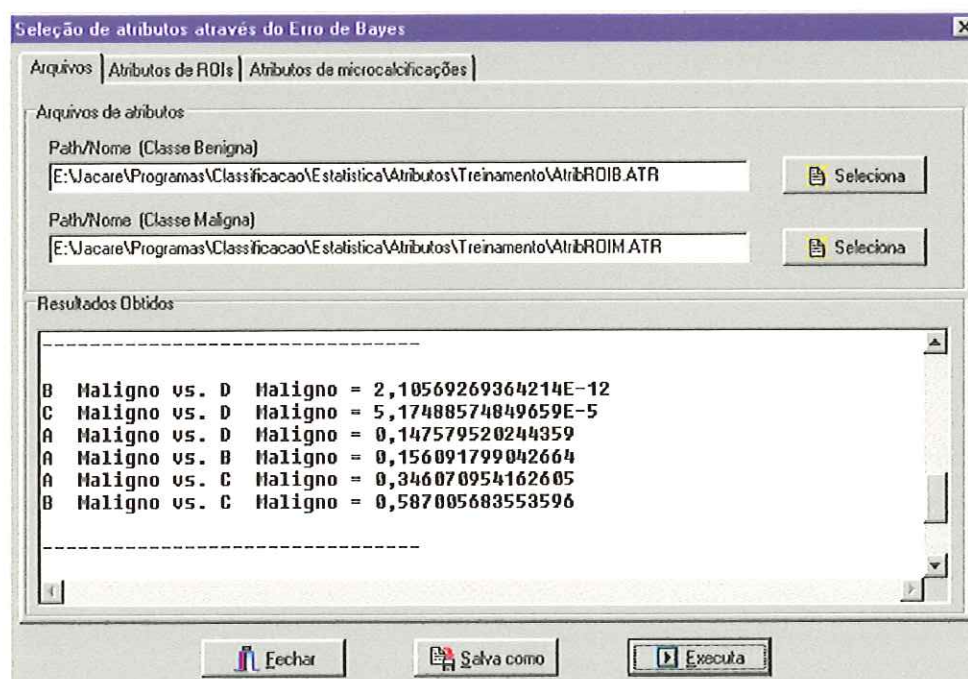
Figura 7.13 - Tela do sistema com a relação de atributos de forma das microcalcificações.

Os resultados do estágio de seleção de atributos podem ser visualizados diretamente na tela do computador ou analisados através de um relatório impresso gerado pelo sistema, conforme ilustram as Figuras 7.14, 7.15, 7.16 e 7.17.

Atributos Selecionados	Média das áreas de sobreposição entre as pdfs maligna e benigna
( M ) Medida de informação de correlação 2	0,1302
( E ) Momento da Diferença Inversa	0,1841
( K ) Entropia da Diferença	0,1880
( A ) Entropia	0,2374
( H ) Entropia da Soma	0,3093
( R ) Variância do segundo momento invariante de Hu $\phi_2$ , calculado entre as microcalcificações	0,3216
( L ) Medida de informação de correlação 1	0,3667
( P ) Medida relacionada ao número de microcalcificações	0,4312

A distância JM média calculada para os atributos M, E, K, A, H, R foi igual a 1,3372.

**Tabela 7.1 - Resultado da seleção usando o erro de Bayes e distância de Jeffries-Matusita. Atributos apresentados em ordem crescente de área média de sobreposição calculada para os 4 grupos de treinamento.**



**Figura 7.14 - Exemplo de tela de saída do sistema de seleção de atributos - erro de Bayes.**

Atributos Analisados – Classe Benigna	(Desvio/Media)
A = Entropia de H(yq, yr, d)	0,368256248760849
B = Segundo Momento Angular de H(yq, yr, d)	0,731420675007844
C = Contraste de H(yq, yr, d)	1,441192894054590
D = Correlação de H(yq, yr, d)	0,139806258630509
Atributos Analisados – Classe Maligna	(Desvio/Media)
A = Entropia de H(yq, yr, d)	0,609892134306496
B = Segundo Momento Angular de H(yq, yr, d)	0,890480806089748
C = Contraste de H(yq, yr, d)	1,496315692849890
D = Correlação de H(yq, yr, d)	0,068924461465633
-----	
B Benigno vs. D Benigno = 0,00178295703444675	
A Benigno vs. D Benigno = 0,00257559113620542	
C Benigno vs. D Benigno = 0,00562168781262457	
A Benigno vs. C Benigno = 0,52960923376877	
A Benigno vs. B Benigno = 0,628019373867507	
B Benigno vs. C Benigno = 0,812606012357117	
-----	
B Maligno vs. D Maligno = 2,10569269364214E-12	
C Maligno vs. D Maligno = 5,17488574849659E-5	
A Maligno vs. D Maligno = 0,147579520244359	
A Maligno vs. B Maligno = 0,156091799042664	
A Maligno vs. C Maligno = 0,346070954162605	
B Maligno vs. C Maligno = 0,587005683553596	
-----	
A Benigno vs. A Maligno = 0,364524693346872	
B Benigno vs. B Maligno = 0,572619386689888	
D Benigno vs. D Maligno = 0,61974576059637	
C Benigno vs. C Maligno = 0,98194795181713	

Figura 7.15 - Exemplo de relatório gerado pela etapa de seleção de atributos – erro de Bayes.

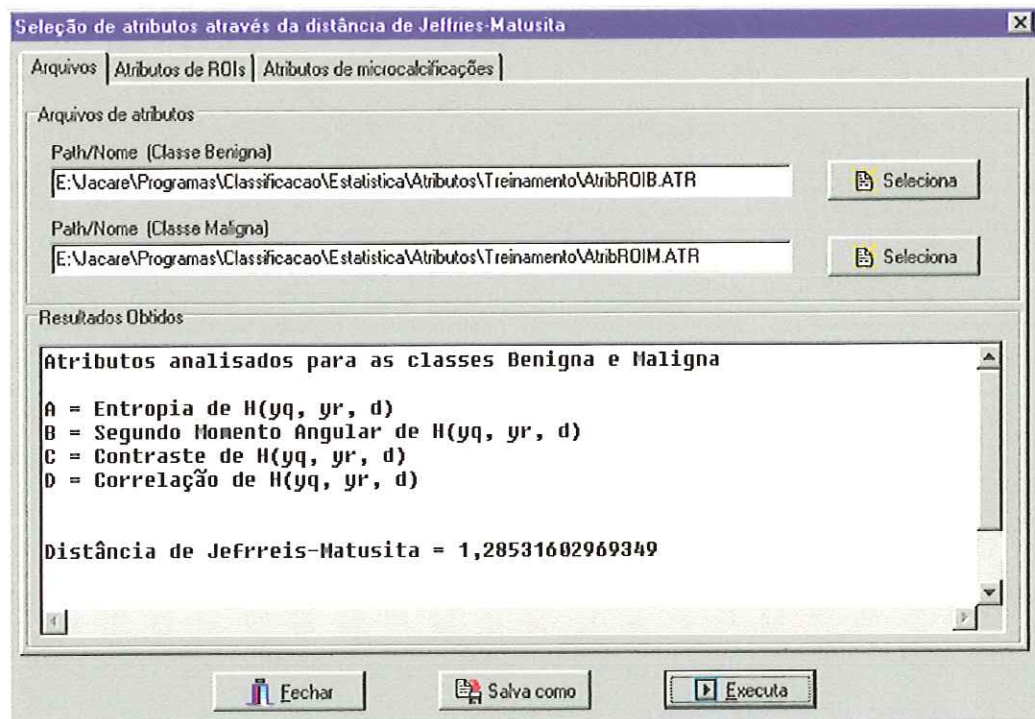


Figura 7.16 - Exemplo de tela de saída do sistema de seleção de atributos – distância JM

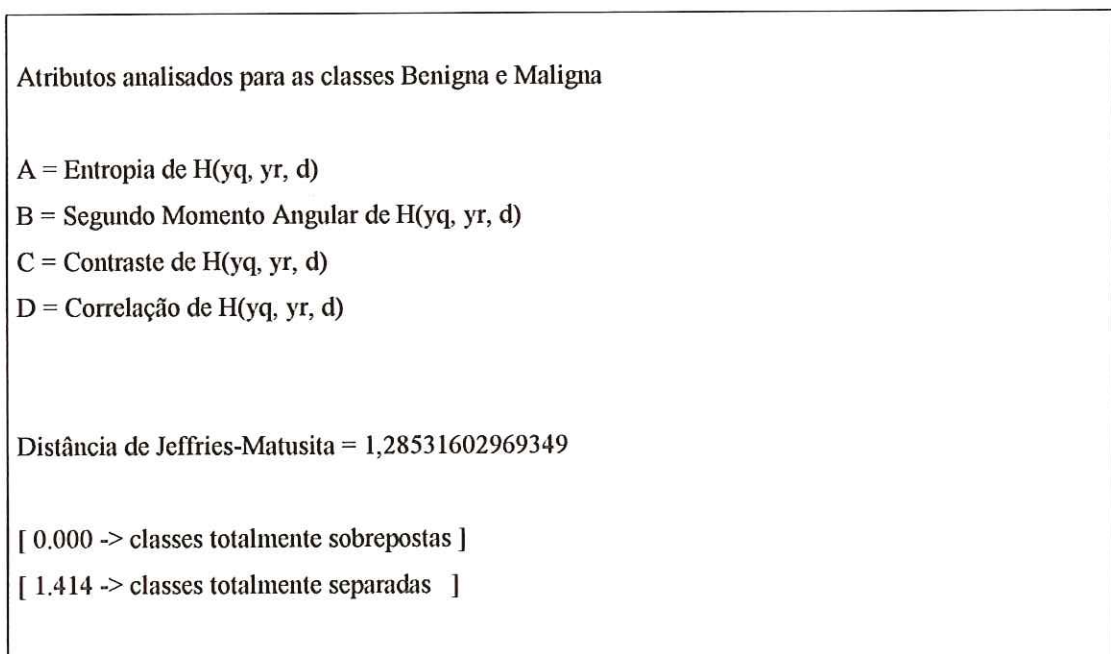


Figura 7.17 - Exemplo de relatório gerado pela etapa de seleção de atributos – distância de Jeffries-Matusita.

## 7.4 – Classificação

Nesta seção são apresentados os resultados obtidos da classificação das amostras de testes utilizando a técnica de validação “leave-k-out”. As tabelas apresentadas a seguir mostram os resultados médios e os desvios padrão calculados para os quatro grupos de teste. Cada grupo de teste é representado por 25 amostras.

### 7.4.1 – Regra de Bayes

Para a avaliação dos classificadores de Bayes, diferentes ensaios foram realizados através da modificação dos seguintes parâmetros: probabilidades de ocorrência das classes benigna e maligna (  $P(B)$  e  $P(M)$  ), custos associados aos falso-positivos  $C(FP)$  e falso-negativos  $C(FN)$  e o limiar de rejeição. No caso da classificação com rejeição, a amostra a ser classificada é rejeitada (não classificada) caso o maior valor da probabilidade *a posteriori* seja inferior ao limiar de rejeição. Para a realização das medidas utilizou-se um limiar de 70%.

#### Classificador Linear

Parâmetros do Classificador $P(B) = 50\%$ $P(M) = 50\%$		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
		Classe Benigna		Classe Maligna	
$C(FP)$ (%)	$C(FN)$ (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
10	90	(68) 13,8564	(32) 13,8564	(95) 7,5719	(5) 7,5719
20	80	(80) 10,3280	(20) 10,3280	(92) 10,8321	(8) 10,8321
30	70	(86) 6,9282	(14) 6,9282	(84) 11,3137	(16) 11,3137
40	60	(89) 3,8297	(11) 3,8297	(82) 16,8127	(18) 16,8127

Tabela 7.2 - Avaliação do classificador linear através da variação dos custos do FP e FN, mantendo  $P(B)=P(M)=50\%$ .



Parâmetros do Classificador P(B) = 60% P(M) = 40%		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
		Classe Benigna		Classe Maligna	
C(FP) (%)	C(FN) (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
10	90	(74) 13,8564	(26) 13,8564	(94) 6,9282	(6) 6,9282
20	80	(84) 6,5320	(16) 6,5320	(86) 13,2665	(14) 13,2665
30	70	(89) 3,8297	(11) 3,8297	(82) 15,1438	(18) 15,1438
40	60	(92) 4,6188	(8) 4,6188	(73) 8,8694	(27) 8,8694

**Tabela 7.3 - Avaliação do classificador linear através da variação dos custos do FP e FN, mantendo P(B)=60% e P(M)=40%.**

Parâmetros do Classificador P(B) = 70% P(M) = 30%		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
		Classe Benigna		Classe Maligna	
C(FP) (%)	C(FN) (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
10	90	(81) 8,8694	(19) 8,8694	(92) 10,8321	(8) 10,8321
20	80	(88) 5,6569	(12) 5,6569	(83) 13,2162	(17) 13,2162
30	70	(92) 4,6188	(8) 4,6188	(73) 8,8694	(27) 8,8694
40	60	(94) 5,1640	(6) 5,1640	(68) 6,5320	(32) 6,5320

**Tabela 7.4 - Avaliação do classificador linear através da variação dos custos do FP e FN, mantendo P(B)=70% e P(M)=30%.**

Parâmetros do Classificador P(B) = 80% P(M) = 20%		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
		Classe Benigna		Classe Maligna	
C(FP) (%)	C(FN) (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
10	90	(86) 6,9282	(14) 6,9282	(84) 14,2361	(16) 14,2361
20	80	(92) 4,6188	(8) 4,6188	(73) 8,8694	(27) 8,8694
30	70	(94) 5,1640	(6) 5,1640	(68) 6,5320	(32) 6,5320
40	60	(96) 3,2660	(4) 3,2660	(65) 3,8297	(35) 3,8297

**Tabela 7.5 - Avaliação do classificador linear através da variação dos custos do FP e FN, mantendo P(B)=80% e P(M)=20%.**

Parâmetros do Classificador P(B) = 90% P(M) = 10%		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
		Classe Benigna		Classe Maligna	
C(FP) (%)	C(FN) (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
10	90	(92) 4,6188	(8) 4,6188	(73) 8,8694	(27) 8,8694
20	80	(95) 3,8297	(5) 3,8297	(65) 3,8297	(35) 3,8297
30	70	(99) 2	(1) 2	(63) 6	(37) 6
40	60	(100) 0	(0) 0	(61) 6,8313	(39) 6,8313

Tabela 7.6 - Avaliação do classificador linear através da variação dos custos do FP e FN, mantendo P(B)=90% e P(M)=10%.




Figura 7.18 - Curva ROC obtida para o classificador linear de Bayes usando os dados das tabelas 7.2, 7.3, 7.4, 7.5 e 7.6.

Parâmetros do Classificador		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
		Classe Benigna		Classe Maligna	
P(B) (%)	P(M) (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
90	10	(100) 0	(0) 0	(60) 5,6569	(40) 5,6569
80	20	(99) 2	(1) 2	(63) 6	(37) 6
70	30	(97) 3,8297	(3) 3,8297	(65) 3,8297	(35) 3,8297
60	40	(95) 3,8297	(5) 3,8297	(66) 4	(34) 4
50	50	(92) 4,6188	(8) 4,6188	(73) 8,8694	(27) 8,8694

**Tabela 7.7 – Avaliação do classificador linear através da variação das probabilidades P(B) e P(M), para o critério de máxima probabilidade *a posteriori*.**

Parâmetros do Classificador		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
		Classe Benigna		Classe Maligna	
P(B) (%)	P(M) (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
90	10	(92) 4,6188	(8) 4,6188	(73) 8,8694	(27) 8,8694
80	20	(86) 6,9282	(14) 6,9282	(84) 14,2361	(16) 14,2361
70	30	(81) 8,8694	(19) 8,8694	(92) 10,8321	(8) 10,8321
60	40	(74) 13,8564	(26) 13,8564	(94) 6,9282	(6) 6,9282
50	50	(68) 13,8564	(32) 13,8564	(95) 7,5719	(5) 7,5719

**Tabela 7.8 - Avaliação do classificador linear através da variação das probabilidades P(B) e P(M), mantendo C(FP)=10% e C(FN)=90%.**

Parâmetros do Classificador		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
		Classe Benigna		Classe Maligna	
P(B) (%)	P(M) (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
90	10	(95) 3,8297	(5) 3,8297	(65) 3,8297	(35) 3,8297
80	20	(92) 4,6188	(8) 4,6188	(73) 8,8694	(27) 8,8694
70	30	(88) 5,6569	(12) 5,6569	(83) 13,2162	(17) 13,2162
60	40	(84) 6,5320	(16) 6,5320	(86) 13,2665	(14) 13,2665
50	50	(80) 10,3280	(20) 10,3280	(92) 10,8321	(8) 10,8321

**Tabela 7.9 - Avaliação do classificador linear através da variação das probabilidades P(B) e P(M), mantendo C(FP)=20% e C(FN)=80%.**

Parâmetros do Classificador		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
C(FP) = 30% C(FN) = 70%		Classe Benigna		Classe Maligna	
P(B) (%)	P(M) (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
90	10	(99) 2	(1) 2	(63) 6	(37) 6
80	20	(94) 5,1640	(6) 5,1640	(68) 6,5320	(32) 6,5320
70	30	(92) 4,6188	(8) 4,6188	(73) 8,8694	(27) 8,8694
60	40	(89) 3,8297	(11) 3,8297	(82) 15,1438	(18) 15,1438
50	50	(86) 6,9282	(14) 6,9282	(84) 11,3137	(16) 11,3137

**Tabela 7.10 - Avaliação do classificador linear através da variação das probabilidades P(B) e P(M), mantendo C(FP)=30% e C(FN)=70%.**

Parâmetros do Classificador		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
C(FP) = 40% C(FN) = 60%		Classe Benigna		Classe Maligna	
P(B) (%)	P(M) (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
90	10	(100) 0	(0) 0	(61) 6,8313	(39) 6,8313
80	20	(96) 3,2660	(4) 3,2660	(65) 3,8297	(35) 3,8297
70	30	(94) 5,1640	(6) 5,1640	(68) 6,5320	(32) 6,5320
60	40	(92) 4,6188	(8) 4,6188	(73) 8,8694	(27) 8,8694
50	50	(89) 3,8297	(11) 3,8297	(82) 16,8127	(18) 16,8127

**Tabela 7.11 - Avaliação do classificador linear através da variação das probabilidades P(B) e P(M), mantendo C(FP)=40% e C(FN)=60%.**




Figura 7.19 - Curva ROC obtida para o classificador linear de Bayes usando os dados das tabelas 7.8, 7.9, 7.10 e 7.11.

Parâmetros do Classificador		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste					
		Classe Benigna			Classe Maligna		
Limiar de rejeição=0,30		Acertos (%)	Erros (%)	Rejeição (%)	Acertos (%)	Erros (%)	Rejeição (%)
P(B) (%)	P(M) (%)						
90	10	(99) 2	(0) 0	(1) 2	(57) 6	(37) 6	(6) 2,3094
80	20	(95) 3,8297	(0) 0	(5) 3,8297	(59) 8,2462	(36) 4,6188	(6) 2,3094
70	30	(92) 4,6188	(0) 0	(8) 4,6188	(61) 6,8313	(29) 12,8062	(10) 7,6594
60	40	(89) 3,8297	(1) 2	(10) 5,1640	(64) 4,6188	(21) 15,7903	(15) 11,4891
50	50	(86) 6,9282	(3) 3,8297	(11) 5,0332	(64) 4,6188	(20) 10,3280	(16) 6,5320

Tabela 7.12 - Avaliação do classificador linear através da variação das probabilidades de ocorrência das classes. Mínimo erro para limiar de rejeição  $\lambda=0,30$  e matriz de custos 0-1.

As tabelas 7.2, 7.3, 7.4, 7.5 e 7.6 apresentam os resultados médios obtidos para o ensaio realizado variando os custos do falso-positivo e falso-negativo com as probabilidades de ocorrência das classes maligna e benigna constantes para cada tabela. Para esse ensaio, os melhores resultados (em termos de sensibilidade) foram :

Tabela 7.2

95% de sensibilidade com 68% de especificidade

$P(B) = 50\%$  ;  $P(M) = 50\%$  -  $C(FN) = 90\%$  ;  $C(FP) = 10\%$

Tabela 7.3

94% de sensibilidade com 74% de especificidade

$P(B) = 60\%$  ;  $P(M) = 40\%$  -  $C(FN) = 90\%$  ;  $C(FP) = 10\%$

Tabela 7.4

92% de sensibilidade com 81% de especificidade

$P(B) = 70\%$  ;  $P(M) = 30\%$  -  $C(FN) = 90\%$  ;  $C(FP) = 10\%$

Pode-se observar que a medida em que a razão  $P(B)/P(M)$  aumenta, a sensibilidade do sistema diminui. Isso ocorre porque as probabilidades *a priori*  $P(B)$  e  $P(M)$  estão diretamente relacionadas às probabilidades *a posteriori*  $P(C_B|x)$  e  $P(C_M|x)$ , respectivamente, através da regra de Bayes. Os custos do FP e FN, quando utilizados, fazem com que o classificador tome a decisão por uma das classes não mais pela maior probabilidade *a posteriori*, mas sim pelo menor risco da classificação. Por isso, os melhores resultados de alta sensibilidade encontram-se associados a altos custos de FN. Os resultados acima representam apenas os melhores pontos de operação do classificador linear.

Na Figura 7.18 são apresentadas as curvas ROC obtidas para cada uma das tabelas citadas acima. Cada curva representa o comportamento global do classificador para diferentes situações, e a área sob a curva é uma forma de medir o seu desempenho, vide capítulo 6 seção 6.4. O classificador linear apresentou o melhor desempenho global ( $AUC = 0,9046$ ) para  $P(B) = 70\%$  e  $P(M) = 30\%$ .



As tabelas 7.7, 7.8, 7.9, 7.10 e 7.11 mostram os mesmos resultados obtidos anteriormente, mas usando uma outra organização. Cada tabela apresenta os resultados médios obtidos variando as probabilidades *a priori*  $P(B)$  e  $P(M)$  com os custos FP e FN fixos.

A Figura 7.19 mostra as curvas ROC obtidas para essas tabelas. Novamente, essas curvas representam o desempenho global do sistema mediante a alteração das situações. O melhor desempenho global foi atingido para a situação  $C(FP) = 20\%$  e  $C(FN) = 80\%$ , com o valor da área sob a curva igual a 0,9055.

A tabela 7.12 apresenta os resultados do ensaio realizado para mínimo erro com limiar de rejeição  $\lambda=0,30$  e matriz de custos 0-1. O uso do limiar de rejeição na tarefa de classificação pode ser de extrema importância na área médica. Para os casos onde a classificação é realizada no limite de separação entre as classes, o grau de precisão na classificação pode ser baixo. Nesses casos, a melhor atitude é deixar essa tarefa para um médico especialista. Para esses resultados, observa-se que a taxa de falso-positivos permaneceu muito baixa (em torno de 3%), mesmo para a situação limite onde  $P(M) = P(B) = 50\%$ . No entanto, a taxa de falso-negativos é relativamente alta (20 à 37%).

### Classificador Quadrático

Parâmetros do Classificador  $P(B) = 50\%$ $P(M) = 50\%$		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
		Classe Benigna		Classe Maligna	
$C(FP)$ (%)	$C(FN)$ (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
10	90	(93) 6	(7) 6	(74) 4	(26) 4
20	80	(95) 6	(5) 6	(71) 3,8297	(29) 3,8297
30	70	(95) 6	(5) 6	(71) 3,8297	(29) 3,8297
40	60	(95) 6	(5) 6	(69) 2	(31) 2

Tabela 7.13 - Avaliação do classificador quadrático através da variação dos custos do FP e FN, mantendo  $P(B)=P(M)=50\%$ .

Parâmetros do Classificador		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
P(B) = 60% P(M) = 40%		Classe Benigna		Classe Maligna	
C(FP) (%)	C(FN) (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
10	90	(95) 6	(5) 6	(71) 3,8297	(29) 3,8297
20	80	(95) 6	(5) 6	(71) 3,8297	(29) 3,8297
30	70	(95) 6	(5) 6	(69) 2	(31) 2
40	60	(95) 6	(5) 6	(68) 3,266	(32) 3,266

**Tabela 7.14 - Avaliação do classificador quadrático através da variação dos custos do FP e FN, mantendo P(B)=60% e P(M)=40%.**

Parâmetros do Classificador		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
P(B) = 70% P(M) = 30%		Classe Benigna		Classe Maligna	
C(FP) (%)	C(FN) (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
10	90	(95) 6	(5) 6	(71) 3,8297	(29) 3,8297
20	80	(95) 6	(5) 6	(70) 2,3094	(30) 2,3094
30	70	(95) 6	(5) 6	(68) 3,266	(32) 3,266
40	60	(96) 4,6188	(4) 4,6188	(68) 3,266	(32) 3,266

**Tabela 7.15 - Avaliação do classificador quadrático através da variação dos custos do FP e FN, mantendo P(B)=70% e P(M)=30%.**

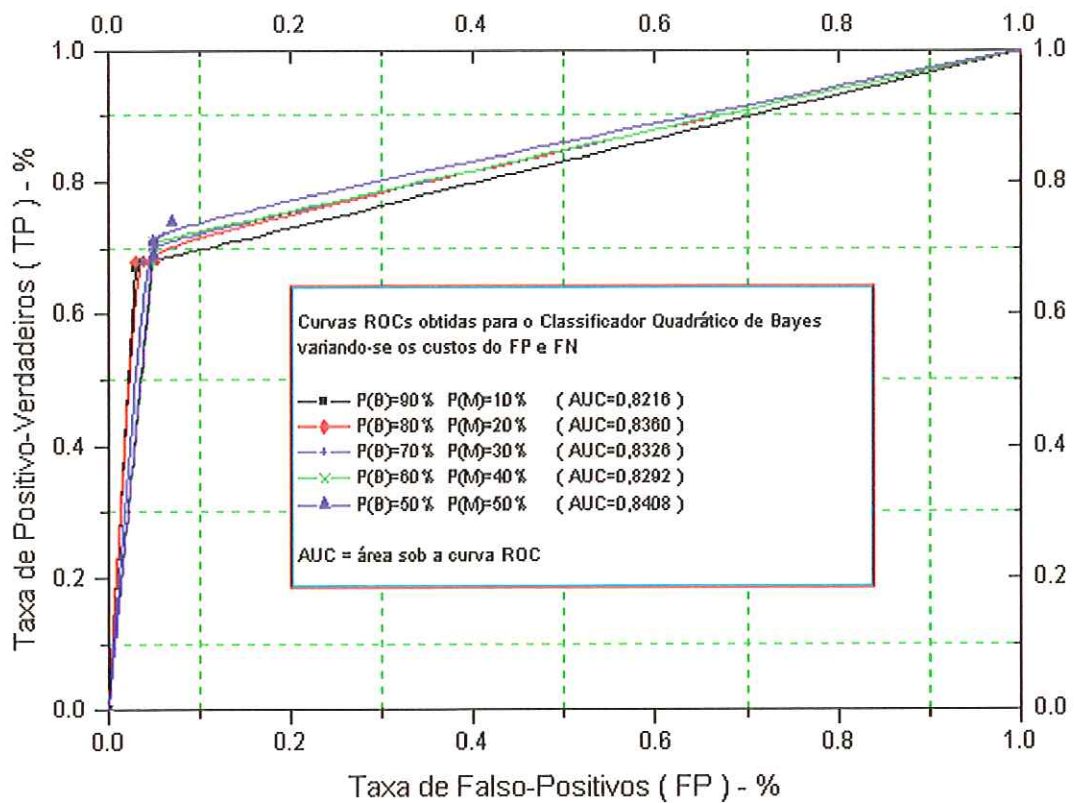
Parâmetros do Classificador		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
P(B) = 80% P(M) = 20%		Classe Benigna		Classe Maligna	
C(FP) (%)	C(FN) (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
10	90	(95) 6	(5) 6	(71) 3,8297	(29) 3,8297
20	80	(95) 6	(5) 6	(68) 3,266	(32) 3,266
30	70	(96) 4,6188	(4) 4,6188	(68) 3,266	(32) 3,266
40	60	(97) 3,8297	(3) 3,8297	(68) 3,266	(32) 3,266

**Tabela 7.16 - Avaliação do classificador quadrático através da variação dos custos do FP e FN, mantendo P(B)=80% e P(M)=20%.**



Parâmetros do Classificador  P(B) = 90% P(M) = 10%		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
		Classe Benigna		Classe Maligna	
C(FP) (%)	C(FN) (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
10	90	(95) 6	(5) 6	(68) 3,266	(32) 3,266
20	80	(96) 4,6188	(4) 4,6188	(68) 3,266	(32) 3,266
30	70	(97) 3,8297	(3) 3,8297	(67) 2	(33) 2
40	60	(97) 3,8297	(3) 3,8297	(67) 2	(33) 2

**Tabela 7.17 - Avaliação do classificador quadrático através da variação dos custos do FP e FN, mantendo P(B)=90% e P(M)=10%**



**Figura 7.20 - Curva ROC obtida para o classificador linear de Bayes usando os dados das tabelas 7.13 , 7.14, 7.15, 7.16 e 7.17.**

Parâmetros do Classificador		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
		Classe Benigna		Classe Maligna	
P(B) (%)	P(M) (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
90	10	(97) 3,8297	(3) 3,8297	(67) 2	(33) 2
80	20	(97) 3,8297	(3) 3,8297	(67) 2	(33) 2
70	30	(96) 4,6188	(4) 4,6188	(68) 3,2660	(32) 3,2660
60	40	(96) 4,6188	(4) 4,6188	(68) 3,2660	(32) 3,2660
50	50	(96) 4,6188	(4) 4,6188	(68) 3,2660	(32) 3,2660

**Tabela 7.18 - Avaliação do classificador quadrático através da variação das probabilidades P(B) e P(M), para o critério de máxima probabilidade *a posteriori*.**

Parâmetros do Classificador		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
		Classe Benigna		Classe Maligna	
P(B) (%)	P(M) (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
90	10	(95) 6	(5) 6	(68) 3,266	(32) 3,266
80	20	(95) 6	(5) 6	(71) 3,8297	(29) 3,8297
70	30	(95) 6	(5) 6	(71) 3,8297	(29) 3,8297
60	40	(95) 6	(5) 6	(71) 3,8297	(29) 3,8297
50	50	(93) 6	(7) 6	(74) 4	(26) 4

**Tabela 7.19 - Avaliação do classificador quadrático através da variação das probabilidades P(B) e P(M), mantendo C(FP)=10% e C(FN)=90%.**

Parâmetros do Classificador		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
		Classe Benigna		Classe Maligna	
P(B) (%)	P(M) (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
90	10	(96) 4,6188	(4) 4,6188	(68) 3,266	(32) 3,266
80	20	(95) 6	(5) 6	(68) 3,266	(32) 3,266
70	30	(95) 6	(5) 6	(70) 2,3094	(30) 2,3094
60	40	(95) 6	(5) 6	(71) 3,8297	(29) 3,8297
50	50	(95) 6	(5) 6	(71) 3,8297	(29) 3,8297

**Tabela 7.20 - Avaliação do classificador quadrático através da variação das probabilidades P(B) e P(M), mantendo C(FP)=20% e C(FN)=80%.**

Parâmetros do Classificador		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
C(FP) = 30% C(FN) = 70%		Classe Benigna		Classe Maligna	
P(B) (%)	P(M) (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
90	10	(97) 3,8297	(3) 3,8297	(67) 2	(33) 2
80	20	(96) 4,6188	(4) 4,6188	(68) 3,266	(32) 3,266
70	30	(95) 6	(5) 6	(68) 3,266	(32) 3,266
60	40	(95) 6	(5) 6	(69) 2	(31) 2
50	50	(95) 6	(5) 6	(71) 3,8297	(29) 3,8297

**Tabela 7.21 - Avaliação do classificador quadrático através da variação das probabilidades P(B) e P(M), mantendo C(FP)=30% e C(FN)=70%.**

Parâmetros do Classificador		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
C(FP) = 40% C(FN) = 60%		Classe Benigna		Classe Maligna	
P(B) (%)	P(M) (%)	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
90	10	(97) 3,8297	(3) 3,8297	(67) 2	(33) 2
80	20	(97) 3,8297	(3) 3,8297	(68) 3,266	(32) 3,266
70	30	(96) 4,6188	(4) 4,6188	(68) 3,266	(32) 3,266
60	40	(95) 6	(5) 6	(68) 3,266	(32) 3,266
50	50	(95) 6	(5) 6	(69) 2	(31) 2

**Tabela 7.22 - Avaliação do classificador quadrático através da variação das probabilidades P(B) e P(M), mantendo C(FP)=40% e C(FN)=60%.**

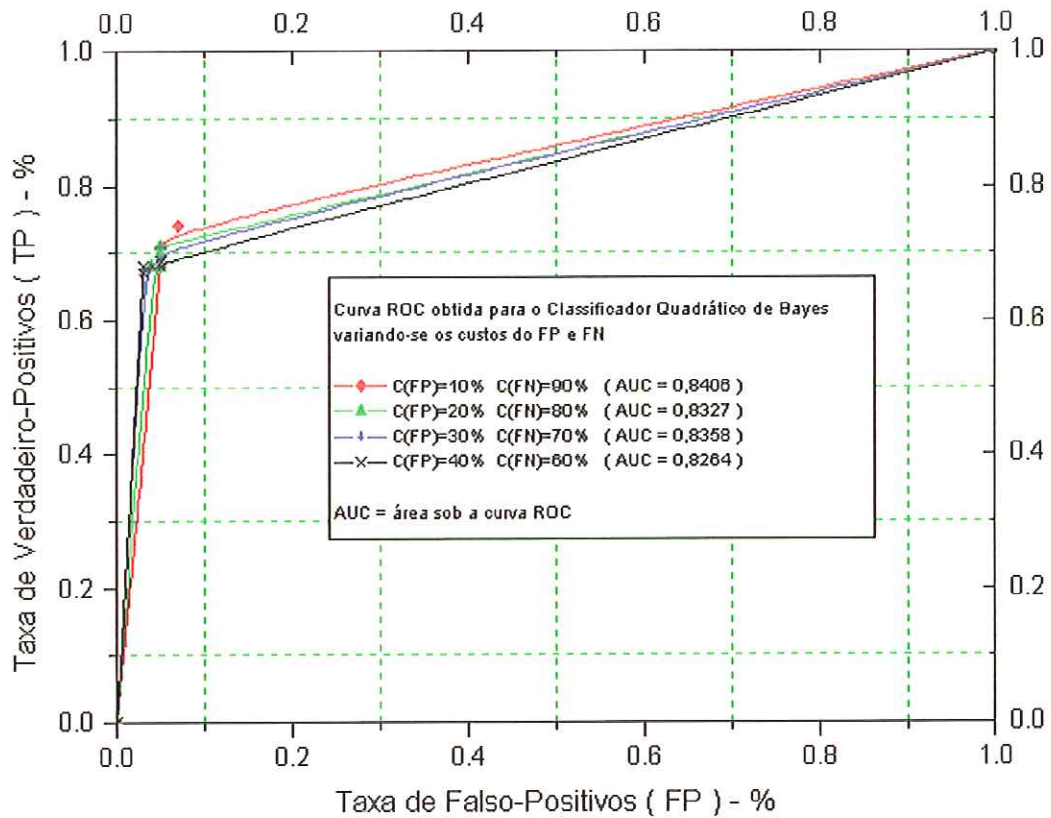


Figura 7.21 - Curva ROC obtida para o classificador linear de Bayes usando os dados das tabelas 7.18 , 7.19, 7.20, 7.21 e 7.22.

Parâmetros do Classificador		Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste											
		Classe Benigna			Classe Maligna								
Limiar de Rejeição=0,30		P(B) (%)	P(M) (%)	Acertos (%)	Erros (%)	Rejeição (%)	Acertos (%)	Erros (%)	Rejeição (%)				
90	10	(97)	3,8297	(3)	3,8297	(0)	0	(66)	2,3094	(33)	2	(1)	2
80	20	(96)	4,6188	(3)	3,8297	(1)	2	(67)	2	(32)	3,2660	(1)	2
70	30	(95)	6	(3)	3,8297	(2)	2,3094	(67)	2	(32)	3,2660	(1)	2
60	40	(95)	6	(3)	3,8297	(2)	2,3094	(67)	2	(32)	3,2660	(1)	2
50	50	(95)	6	(4)	4,6188	(1)	2	(67)	2	(31)	3,8297	(2)	2,3094

Tabela 7.23 - Avaliação do classificador linear através da variação das probabilidades de ocorrência das classes. Mínimo erro para limiar de rejeição  $\lambda=0,30$  e matriz de custos 0-1.

As tabelas 7.13, 7.14, 7.15, 7.16 e 7.17 apresentam os resultados médios obtidos para o classificador quadrático variando os custos do falso-positivo e falso-negativo com as probabilidades de ocorrência das classes maligna e benigna constantes para cada tabela. O melhor resultado (em termos de sensibilidade) obtido para esse ensaio foi :

Tabela 7.13

74% de sensibilidade com 93% de especificidade

$P(B) = 50\%$  ;  $P(M) = 50\%$  -  $C(FN) = 90\%$  ;  $C(FP) = 10\%$

Os resultados obtidos para o classificador quadrático se mostraram bem aquém aos obtidos pelo classificador linear. A sensibilidade apresentada por esse classificador foi muito baixa. No entanto, para todas as situações, a especificidade alcançada pelo classificador quadrático foi maior que a obtida para o linear. Também, observa-se nas Figuras 7.20 e 7.21 que os resultados obtidos para esse classificador, em diferentes situações, se mantiveram praticamente inalterados, com área sob a curva ROC em torno de 0,83.

Com relação aos resultados mostrados anteriormente, cabe salientar que a média amostral e a matriz de covariância estimadas por máxima verossimilhança têm a propriedade que maximiza a probabilidade das amostras de treinamento, as quais são assumidas ser estatisticamente independentes, [HOFFBECK-96]. A regra de classificação que resulta substituindo a máxima probabilidade estimada para a média e matriz de covariâncias na forma funcional Gaussiana, como se estes valores fossem a média e a matriz de covariância verdadeiras, atinge a classificação ótima apenas assintoticamente com o número de amostras de treinamento tendendo ao infinito. Esse esquema de classificação não é ótimo quando a amostra de treinamento é pequena. Portanto, para um grupo de amostras limitada, a estimação da matriz de covariância comum ( $S = \frac{1}{L} \sum_{i=1}^L \Sigma_i$ ) pode permitir maior exatidão na classificação, mesmo quando as matrizes de covariâncias são diferentes. Isso está relacionado também ao maior número de parâmetros livres apresentados pelo classificador quadrático em relação ao linear. Se o número de parâmetros do classificador é grande, comparado com o número de amostras, pode-se

cair num problema de overfitting. Nesse caso a estimação da função de decisão implementada pode estar levando em consideração detalhes específicos das amostras de treinamento, incluindo ruídos, ao invés de usar características gerais das amostras. Com isso o poder de generalização do classificador, ou seja, capacidade de classificar corretamente amostras não pertencentes ao grupo de treinamento, pode ficar comprometido. Para um vetor de atributos  $p$ -dimensional, a matriz de covariância da amostra é singular se apenas grupos de tamanho  $p+1$  de amostras de treinamento de cada classe estão disponíveis, o estimador será pobre e os parâmetros esperados diferirão completamente dos valores verdadeiros (estimador com alto grau de polarização) [HOFFBECK-96].

## 7.4.2 – Método k-NN

A avaliação do classificador k-NN foi realizada variando os três parâmetros que o descrevem, que são: o valor de k, que representa o número de vizinhos mais próximos, e os limiares  $M_B$  e  $M_M$  que determinam o número mínimo de amostras classificadas para as classes benigna e maligna, respectivamente, dentro dos k vizinhos analisados.

Parâmetros do Classificador			Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
			Classe Benigna		Classe Maligna	
K	$M_B$	$M_M$	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
5	3	3	(84) 9,2376	(16) 9,2376	(81) 14	(19) 14
7	4	4	(86) 12	(14) 12	(77) 15,4488	(23) 15,4488
9	5	5	(90) 7,6594	(10) 7,6594	(79) 15,0997	(21) 15,0997
11	6	6	(89) 6	(11) 6	(79) 16,7730	(21) 16,7730
13	7	7	(88) 7,3030	(12) 7,3030	(80) 14,9666	(20) 14,9666
15	8	8	(87) 8,2462	(13) 8,2462	(81) 15,4488	(19) 15,4488
17	9	9	(87) 8,2462	(13) 8,2462	(82) 15,4919	(18) 15,4919
19	10	10	(87) 8,2462	(13) 8,2462	(82) 15,4919	(18) 15,4919

Tabela 7.24 - Método k-NN: Classificação sem rejeição e baixa sensibilidade.

Parâmetros do Classificador			Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
			Classe Benigna		Classe Maligna	
K	$M_B$	$M_M$	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
5	5	1	(60) 9,7980	(40) 9,7980	(98) 4	(2) 4
7	7	1	(50) 13,6626	(50) 13,6626	(98) 4	(2) 4
9	9	1	(46) 15,4919	(54) 15,4919	(99) 2	(1) 2
11	11	1	(41) 17,3973	(59) 17,3973	(99) 2	(1) 2
13	13	1	(35) 17,3973	(65) 17,3973	(99) 2	(1) 2
15	15	1	(32) 19,0438	(68) 19,0438	(99) 2	(1) 2
17	17	1	(30) 20,2649	(70) 20,2649	(99) 2	(1) 2
19	19	1	(26) 22,7450	(74) 22,7450	(99) 2	(1) 2

Tabela 7.25 - Método k-NN: Classificação sem rejeição e alta sensibilidade.

Parâmetros do Classificador			Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste					
			Classe Benigna			Classe Maligna		
K	M <sub>B</sub>	M <sub>M</sub>	Acertos (%)	Erros (%)	Rejeição (%)	Acertos (%)	Erros (%)	Rejeição (%)
5	5	5	(60) 9,7980	(2) 2,3094	(38) 8,3267	(60) 5,6569	(2) 4	(38) 2,3094
7	7	7	(50) 13,6626	(0) 0	(50) 13,6626	(60) 5,6569	(2) 4	(38) 2,3094
9	9	9	(46) 15,4919	(0) 0	(54) 15,4919	(60) 5,6569	(1) 2	(39) 3,8297
11	11	11	(41) 17,3973	(0) 0	(59) 17,3973	(60) 5,6569	(1) 2	(39) 3,8297
13	13	13	(35) 17,3973	(0) 0	(65) 17,3973	(60) 5,6569	(1) 2	(39) 3,8297
15	15	15	(32) 19,0438	(0) 0	(68) 19,0438	(60) 5,6569	(1) 2	(39) 3,8297
17	17	17	(30) 20,2649	(0) 0	(70) 20,2649	(60) 5,6569	(1) 2	(39) 3,8297
19	19	19	(26) 22,7450	(0) 0	(74) 22,7450	(60) 5,6569	(1) 2	(39) 3,8297

Tabela 7.26 - Método k-NN: Classificação com rejeição e alto grau de certeza.

Parâmetros do Classificador			Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
			Classe Benigna		Classe Maligna	
K	M <sub>B</sub>	M <sub>M</sub>	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
11	11	1	(41) 17,3973	(59) 17,3973	(99) 2	(1) 2
11	9	3	(64) 11,7757	(36) 11,7757	(92) 10,8321	(8) 10,8321
11	7	5	(81) 5,0332	(19) 5,0332	(85) 11,9443	(15) 11,9443
11	5	7	(92) 7,3030	(8) 7,3030	(73) 14,3759	(27) 14,3759
11	3	9	(98) 4	(2) 4	(61) 6,8313	(39) 6,8313
11	1	11	(100) 0	(0) 0	(60) 5,6569	(40) 5,6569

Tabela 7.27 - Método k-NN: Classificação sem rejeição variando o limiar de decisão.



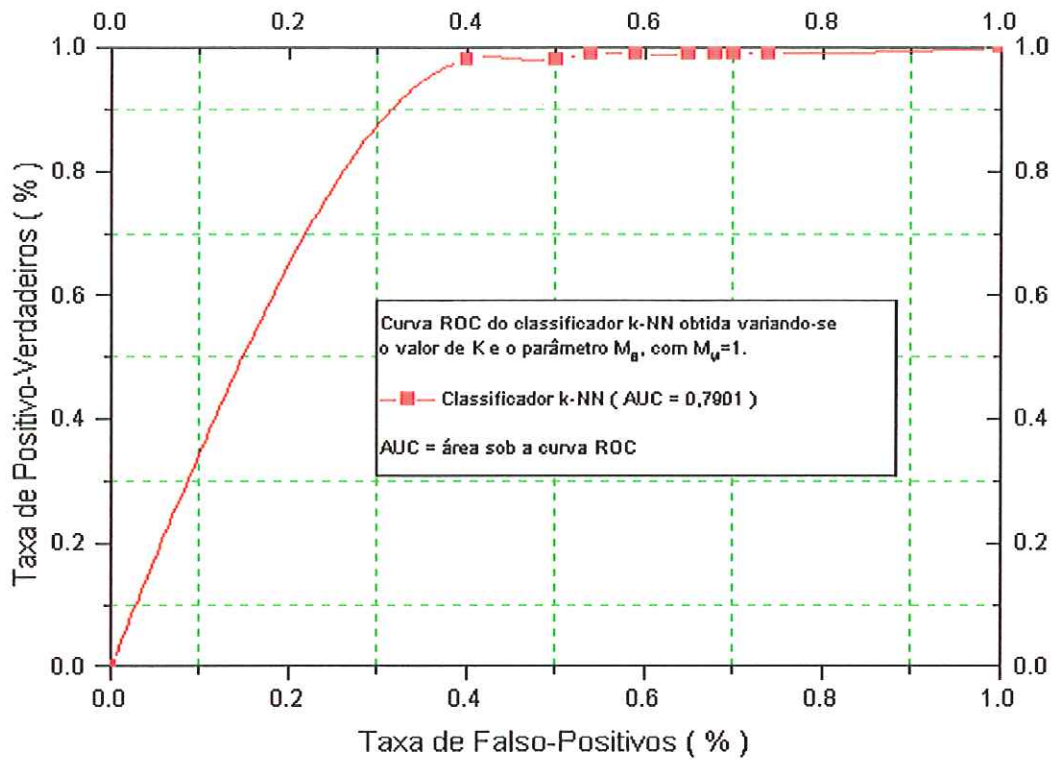


Figura 7.22 - Curva ROC obtida variando-se o valor de k e o limiar  $M_B$  (de 5 a 19) com o limiar  $M_M$  fixo em 1 - dados das tabela 7.25.

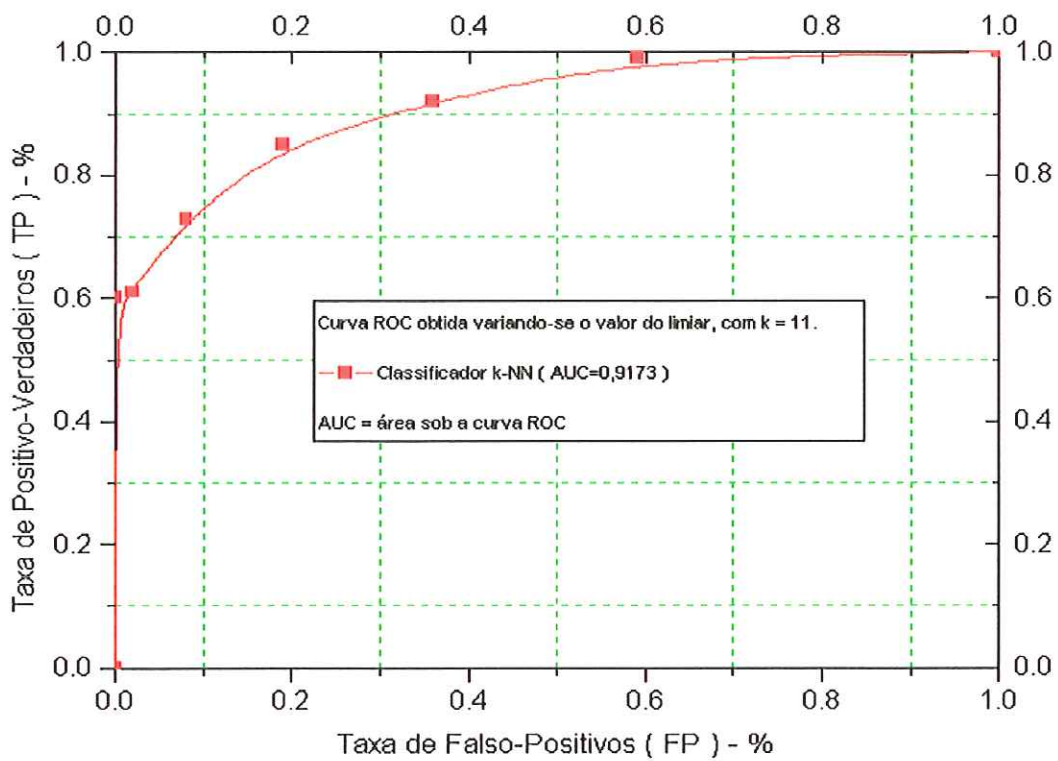


Figura 7.23 - Curva ROC obtida variando-se os limiares  $M_B$  (de 1 a 11) e  $M_M$  (de 11 a 1) - dados das tabela 7.27.

A tabela 7.24 apresenta os resultados do classificador k-NN para várias situações de classificação com baixa sensibilidade. O melhor resultado, em termos da taxa de sensibilidade, foi alcançado para duas diferentes situações:  $k=17$  com  $M_B=M_M=9$  e  $k=19$  com  $M_B=M_M=10$  (sensibilidade=82% e especificidade=87%). O melhor resultado, observado-se a especificidade foi alcançado para  $M_B=M_M=5$  e  $k=9$  (sensibilidade=79% e especificidade=90%).

Os resultados obtidos para o classificador k-NN em situações de alta sensibilidade (limiar  $M_M=1$ ) são apresentados na tabela 7.25. Neste ensaio a taxa de falso-negativo manteve-se em limites aceitáveis (1 e 2%). No entanto a especificidade diminui com o aumento do valor de  $k$ . A Figura 7.22 apresenta o desempenho global para esse classificador através de uma curva ROC, usando os dados da tabela 7.25. A área sob a curva ROC obtida foi de 0,7901. Nota-se que para altos valores de sensibilidade esta associada altas taxas de falso-positivos (maiores que 40%).

Outro ensaio foi realizado para a situação de alto grau de certeza na classificação, tabela 7.26. Nesse caso os valores de  $M_B$  e  $M_M$  são ajustados para os valores máximos ( $k=M_B=M_M$ ), com  $k$  variando de 5 a 19 com passo de 2. Analisando os resultados dessa tabela, nota-se que os valores de sensibilidade para todas as configurações analisadas mantiveram-se inalteradas, havendo ainda pouca alteração na taxa de falso-negativos. Outra observação que pode ser feita e que para todas as situações, com exceção do primeiro caso  $k=5$ ,  $M_M=M_B=5$ , não existiram falso-positivos, no entanto a taxa de rejeição cresceu rapidamente com a variação dos parâmetros.

A tabela 7.27 apresenta os resultados para um valor intermediário do parâmetro  $k$  ( $k=11$ ) e variação dos limiares de rejeição  $M_M$  e  $M_B$ . A Figura 7.23 mostra a curva ROC obtida para os resultados dessa tabela, onde o valor da área sob a curva ( $AUC = 0,9173$ ) descreve o comportamento global desse classificador. O melhor resultado foi alcançado para a configuração  $k=11$ ,  $M_B=11$  e  $M_M=1$ , com sensibilidade de 99% e especificidade de 41%.

### 7.4.3 – Perceptron Multicamadas

A avaliação das redes MLP foi realizada para duas situações: Na primeira, com rejeição, a regra de decisão utiliza dois limiares, de maneira que uma amostra desconhecida é classificada como benigna se a saída da rede for maior que 0,8 e como maligna se a saída for menor que 0,2. Na segunda situação, sem rejeição, a decisão pela classe benigna ocorre quando a saída da rede é maior que 0,5, caso contrário a amostra é classificada como maligna.

### classificação com rejeição

Camadas Escondidas: Número Neurônios	Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste					
	Classe Benigna			Classe Maligna		
	Acertos (%)	Erros (%)	Rejeição (%)	Acertos (%)	Erros (%)	Rejeição (%)
1:4	(82) 5,1640	(18) 5,1640	(0) 0	(82) 4	(17) 3,8297	(1) 2
1:6	(79) 10	(20) 8,6410	(1) 2	(78) 10,0664	(22) 10,0664	(0) 0
1:8	(76) 11,7757	(20) 9,2376	(4) 3,266	(81) 12,3828	(16) 10,8321	(3) 3,8297
1:10	(83) 13,6137	(12) 11,3137	(5) 3,8297	(81) 8,2462	(19) 8,2462	(0) 0
1:12	(76) 10,8321	(23) 8,8694	(1) 2	(75) 6,8313	(23) 6,8313	(2) 2,3094
1:14	(76) 11,7757	(23) 11,0151	(1) 2	(77) 8,8694	(21) 10,5198	(2) 4

Tabela 7.28 - Rede MLP - uma camada intermediária com diferentes números de neurônios – com rejeição.

Camadas Escondidas: Número Neurônios	Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste					
	Classe Benigna			Classe Maligna		
	Acertos (%)	Erros (%)	Rejeição (%)	Acertos (%)	Erros (%)	Rejeição (%)
1:4 - 2:2	(81) 10	(19) 10	(0) 0	(70) 15,4919	(29) 14,3759	(1) 2
1:6 - 2:3	(78) 10,5830	(19) 8,8694	(3) 3,8297	(79) 8,2462	(18) 10,5830	(3) 3,8297
1:8 - 2:4	(72) 8,6410	(24) 9,7980	(4) 3,2660	(79) 10,5198	(19) 9,4516	(2) 2,3094
1:10 - 2:5	(83) 8,8694	(17) 8,8694	(0) 0	(83) 7,5719	(15) 3,8297	(2) 4
1:12 - 2:6	(77) 11,9443	(19) 8,2462	(2) 2,3094	(80) 10,3280	(17) 8,2462	(3) 3,8297
1:14 - 2:7	(76) 19,3218	(21) 15,7903	(3) 3,8297	(75) 3,8297	(20) 4,6188	(6) 2,3094

Tabela 7.29 - Rede MLP - duas camadas intermediárias com diferentes números de neurônios – com rejeição.

**classificação sem rejeição**

Camadas Escondidas: Número Neurônios	Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
	Classe Benigna		Classe Maligna	
	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
1:4	(82) 5,1640	(18) 5,1640	(83) 3,8297	(17) 3,8297
1:6	(79) 10	(21) 10	(78) 10,0664	(22) 10,0664
1:8	(76) 11,7757	(23) 11,0151	(82) 12,4365	(18) 12,4365
1:10	(83) 13,6137	(15) 10	(81) 8,2462	(19) 8,2462
1:12	(76) 10,8321	(23) 8,8694	(75) 6,8313	(25) 6,8313
1:14	(76) 11,7757	(24) 11,7757	(77) 8,8694	(23) 8,8694

**Tabela 7.30 - Rede MLP - uma camada intermediária com diferentes números de neurônios – sem rejeição.**

Camadas Escondidas: Número Neurônios	Percentual médio e desvio-padrão dos resultados dos 4 grupos de teste			
	Classe Benigna		Classe Maligna	
	Acertos (%)	Erros (%)	Acertos (%)	Erros (%)
1:4 - 2:2	(81) 10	(19) 10	(71) 14,3759	(29) 14,3759
1:6 - 2:3	(79) 10,0151	(19) 11,0151	(79) 8,2462	(21) 8,2462
1:8 - 2:4	(74) 7,6594	(24) 7,6594	(80) 11,3137	(20) 11,3137
1:10 - 2:5	(83) 8,8694	(17) 8,8694	(84) 5,6569	(16) 5,6569
1:12 - 2:6	(80) 6,5320	(19) 6,5320	(82) 7,6594	(18) 7,6594
1:14 - 2:7	(77) 17,3973	(21) 17,3973	(79) 6	(21) 6

**Tabela 7.31 - Rede MLP - duas camadas intermediárias com diferentes números de neurônios – sem rejeição.**

As tabelas 7.28 e 7.29 mostram os resultados obtidos para a situação de rejeição com redes MLP de 1 e 2 camadas intermediárias, respectivamente, e diferentes números de neurônios. Os melhores resultados obtidos neste ensaio foram: 83% de sensibilidade com 83% de especificidade para uma rede com 2 camadas intermediárias (1:10 e 2:5) e 82% de sensibilidade e 82 % de especificidade para uma rede com 1 camada intermediária com 4 neurônios.

Os resultados do ensaio realizado para as mesmas redes mas sem a introdução do limiar são apresentados nas tabelas 7.30 e 7.31. Par esse ensaio, os

melhores resultados obtidos foram: 84% de sensibilidade com 83% de especificidade para uma rede com 2 camadas intermediárias (1:10 e 2:5) e 83% de sensibilidade e 82 % de especificidade para uma rede com 1 camada intermediária com 4 neurônios. Como pode ser notado, os resultados apresentados acima foram novamente obtidos para as mesmas topologias das redes do ensaio anterior. O acerto e o erro da classificação das amostras utilizando esse classificador foram realizados com valores bem próximos aos limites da saída da rede (0 ou 1). Isso pode ser observado comparando-se os resultados dos ensaios com e sem o limiar de rejeição para as mesmas topologias da rede.

Uma possível explicação para esse fato é o pequeno número de amostras utilizadas e o grande número de parâmetros livres apresentados por esse tipo de classificador. Dessa forma a rede pode estar decorando os padrões ao invés de aprendê-los ( fenômeno de “overfitting” ). O número de parâmetros livres para as redes MLPs são calculados através da seguinte equação:  $(n+1)*m$ , onde  $n$  é o número de neurônios das camadas intermediárias e  $m$  é a dimensão do vetor de atributos. Nessa equação, o valor numérico 1 representa os valores do “bias”. De acordo com [MASTER-93], para uma amostra de treinamento igual a  $M$  elementos, o número de parâmetros a serem ajustados não devem ser maiores que  $M/2$ . No entanto, a alta dimensão do espaços de atributos, comparado com o número de amostras, não é o único problema que leva o fenômeno "overfitting". Esse fenômeno pode estar relacionado também com a qualidade da solução encontrada durante o treinamento da rede, da distribuição dos dados, da quantidade de ruído presente nos dados e a natureza da função de aproximação.

# Capítulo 8

## Conclusões Finais

A dificuldade na realização do diagnóstico do câncer de mama em seu estágio inicial, juntamente com o grande volume de dados gerados num sistema de diagnóstico hospitalar, têm levado vários grupos de pesquisa a buscar uma solução computacional, para auxiliar os médicos nesse problema.

Um das primeiras conclusões acerca do trabalho realizado é que a escolha e/ou desenvolvimento de uma base de dados de mamogramas representativa da realidade de um serviço hospitalar é fundamental para o sucesso e validade do trabalho. O desempenho do sistema, em todas as suas etapas (detecção, segmentação e classificação) está diretamente relacionado ao conjunto de dados utilizados, tanto para o treinamento e ajustes dos programas quanto para o seu teste. As classes envolvidas no processo de classificação devem estar muito bem representadas pelas amostras de treinamento. Dessa forma o uso de uma base de dados comum para a comparação dos algoritmos, além de regras de "benchmarks" para a realização dos experimentos é de grande importância.

Além da escolha representativa das imagens, o processo de digitalização é também outro fator importante para o bom desempenho de um sistema CAD. O digitalizador deve permitir a digitalização das imagens com as resoluções (contraste e espacial) adequadas e mínima inserção de ruído. As imagens utilizadas neste trabalho possuem 8 bits de quantização e 0,042 mm de tamanho de pixel. Usando essa resolução espacial foi possível apenas segmentar microcalcificações com tamanhos maiores ou iguais a 0,5 mm. As resoluções mínimas de digitalização estão extremamente relacionadas com o objetivo do sistema CAD. Para a determinação dos agrupamentos de microcalcificações, por exemplo, é importante que se tenha um contraste muito alto entre os sinais e as demais estruturas (larga faixa dinâmica), o tamanho do pixel não é tão importante uma vez que não haverá extração de borda dos sinais. Nesse caso, resoluções de 10 bits e 0.042mm são suficientes para o bom desempenho dessa etapa. Quando um sistema CAD é

desenvolvido não apenas para determinar as possíveis regiões suspeitas (contendo microcalcificações), mas também para classificá-las em benigna ou maligna, as resoluções espacial e de contraste devem ser grandes para permitirem a extração perfeita da borda do sinal. Para sistemas com esse objetivo são indicadas resoluções de 10 bits e 0.035 mm.

Com relação aos atributos utilizados, foi possível observar que os de forma, extraídos das microcalcificações, não foram tão eficazes na diferenciação entre as lesões. Este problema está relacionado principalmente ao estágio de segmentação das imagens, que distorce a forma final das microcalcificações. Portanto, apesar do grande número de atributos de forma investigados, apenas um se mostrou eficaz na caracterização da malignidade das ROIs classificadas. Por outro lado, alguns atributos de textura demonstraram-se bastante promissores, podendo ainda alcançar melhores resultados quando utilizados sobre imagens digitalizadas com 10 bits. Na verdade, a classificação foi sustentada principalmente por informações de textura e contraste. Uma possível aplicação para esses atributos, uma vez que a obtenção deles não exige segmentação da imagem, seria na detecção de regiões suspeitas no mamograma.

É importante ressaltar que o uso das técnicas Bayesianas na classificação de lesões de mama, tem a grande vantagem de permitir a inserção de informações *a priori* na realização da classificação, e a partir de seus parâmetros também é possível ajustar o grau de sensibilidade e especificidade desejado. Dessa forma é possível investigar a partir das amostras rejeitadas a possibilidade de implementação de alguma outra medida capaz de garantir o melhor desempenho do sistema. Outra importante característica dos métodos Bayesianos é a possibilidade de utilização de uma técnica interativa de estimação dos seus parâmetros, eliminando a necessidade de se manter armazenado o grupo de amostras de treinamento. No entanto para esses classificadores é importante observar que a modelagem exata das densidades de probabilidades usando um grupo finito de dados em espaços de alta dimensão é em geral extremamente difícil.

Diferente da metodologia Bayesiana, o método não-paramétrico k-NN não necessita de informações *a priori* para a realização da classificação, no entanto requer a presença das amostras de treinamento e tem elevado custo computacional.

As redes neurais MLP, apesar da pouca investigação realizada neste trabalho, mostraram resultados promissores. No entanto, o seu funcionamento não é muito bem determinado, exigindo um tempo muito grande para o ajuste dos seus pesos. Esse método também é extremamente empírico, uma vez que não existem regras pré-estabelecidas para selecionar a melhor topologia da rede.

Por fim, pode-se afirmar que o desempenho do sistema desenvolvido foi bastante satisfatório, levando-se em consideração que: (a) a classificação é realizada sem a avaliação temporal, ou seja, não são utilizadas informações da evolução dos casos ao longo do tempo, (b) não são utilizadas informações clínicas e de posição do agrupamento classificado dentro da mama, (c) não é utilizada a comparação com a mama contralateral.

## **Sugestões para futuros trabalhos**

Nesta seção são descritas algumas sugestões para a realização de trabalhos futuros. Tais sugestões são decorrentes das dificuldades encontradas e experiências adquiridas durante a realização desse trabalho de pesquisa.

- estudo para verificar se as classes estão completamente representadas nos grupos de treinamento: Subgrupos pouco representados dentro dos grupos de treinamento das classes benigna e maligna podem ser interpretados como ruídos e diminuir o desempenho do classificador. Uma possível solução é o uso de métodos de “clustering” para determinação do número de subgrupos em cada classe.
- uso de técnicas de pré-processamento para corrigir as altas variações produzidas pelas estruturas normais da mama no fundo da imagem: A eliminação das altas variações, causadas devido a própria natureza do sistema de imageamento, pode melhorar a taxa de detecção e o processo de segmentação das microcalcificações.



- estudo mais detalhado sobre técnicas de segmentação: O uso da medida da forma das microcalcificações é de grande importância para a classificação das lesões de mama, e novas técnicas de segmentação devem ser investigadas.
- uso de informações clínicas para a classificação de lesões de mama: O uso de uma base de conhecimento, contendo informações clínicas combinadas com informações extraídas das imagens, pode tornar o sistema de auxílio ao diagnóstico mais eficaz.
- aplicação do sistema de classificação em um serviço hospitalar, para ajustes e real avaliação de seu desempenho.
- integração entre os sistemas de classificação e gerenciamento-armazenamento de imagens, permitindo importantes análises estatísticas sobre os dados.

# Referências Bibliográficas

[ACKERMAN-72]

ACKERMAN, L.V.; GOSE, E.E. **Breast lesion classification by computer and xeroradiography.** Cancer, Vol.30,p.1025-1035, 1972.

[CHAN-87]

CHAN, H.-P.; DOI, K.; GALHOTRA, S.; VYBORNY, C.J.; MacMAHON, H.; JOKICH, P.M. **Image feature analysis and computer-aided diagnosis in digital radiography. I. Automated detection of microcalcifications in mammography.** Medical Physics, v. 14(4), p. 538-548, 1987.

[CHAN-88A]

CHAN, H.-P.; DOI, K.; LAM, K.-L.; VYBORNY, C.J.; SCHMIDT, R.A.; METZ, C.E. **Digital characterization of clinical mammographic microcalcifications p. applications in computer-aided detection.** SPIE Med. Imaging II p. Image Formations Detection Processing and Interpretation, v. 914, p. 591-593, 1988.

[CHAN-88B]

CHAN, H.-P.; DOI, K.; VYBORNY, C. J.; LAM, K.-L.; SCHMIDT, R. A. **Computer-aided detection of microcalcifications in mammograms. Methodology and preliminary clinical study.** Original Investigations, 1988.

[CHAN-90]

CHAN, H.-P.; DOI, K.; VYBORNY, C.J.; SCHMIDT, R.A.; METZ, C.E.; LAM, K.L.; OGURA, T.; WU, Y.; MacMAHON, H. **Improvement in radiologists' detection of agrupamentoed microcalcifications on mammograms: the potential of computer-aided diagnosis.** Investive Radiology, v. 25(10), p. 1102-1110, 1990.

[CHAN-94]

CHAN, H.P.; NIKLASON, L.T.; IKEDA, D.M.; LAM, K.L.; ADLER D.D.  
**Digitization requirements in mammography: Effects on computer-aided detection of microcalcifications.** Medical Physics, 21 (7), Julho, 1994.

[CHAN-97]

CHAN, H.P.; SAHNER, B.; PETRICK, N.; HELVIE, M.A.; LAM, K.L.; ADLER, D.D.; GOODSITT, M.M. **Computerized classification of malignant and benign microcalcifications on mammograms: texture analysis using an artificial neural network** Phys. Med. Biol., 42, p. 549-567, 1997.

[CHITRE-94]

CHITRE, Y.; DHAWAN, A. P.; MOSKOWITZ, M. **Artificial Neural Network Based Classification Of Mammographic Microcalcifications Using Image Structure Features** State of Art in Digital Mammographic Image Analysis, World Scientific - New Jersey, pp. 167-197, 1994.

[CIACCIO-93A]

CIACCIO, E.J.; DUNN, S.M.; AKAY, M. **Biosignal Pattern Recognition and Interpretation Systems - Part 1 de 4** IEEE Engineering in Medicine and Biology, Setembro, 1993.

[CIACCIO-93B]

CIACCIO, E.J.; DUNN, S.M.; AKAY, M. **Biosignal Pattern Recognition and Interpretation Systems - Part 2 de 4** IEEE Engineering in Medicine and Biology, Dezembro, 1993.

[CURRY III-90]

CURRY III, T.S.; DOWDEY, J.E.; MURRY JR., R.C. **Christensen's Physics of Diagnostic Radiology.** Lea & Febiger, Philadelphia, 4<sup>th</sup>.Edition, 1990.

[DAVIES-90]

DAVIES, D. H.; DANCE, D. R. **Automatic computer detection of agrupamentoed calcification in digital mammograms.** Physics in Medicine and Biology, v. 35 (8), p. 1111-1118, 1990.

[DEMUTH-94]

DEMUTH, H.; BEALE M. **Neural Network Toolbox User's Guide.** The MathWorks Inc. - Third Printing - Janeiro, 1994.

[DENGLER-93]

DENGLER, J.; BEHRENS, S.; DESAGA, J.F. **Segmentation of Microcalcifications in Mammograms** IEEE Transactions on Medical Imaging, Vol. 12, No. 4, Dezembro, 1993.

[DHAWAN-93]

DHAWAN, A.P.; CHITRE, Y.; MOSKOWITZ, M. **Artificial neural network based classification of mammographic microcalcifications using image structure features** SPIE, Vol. 1905, Agosto, 1993.

[DICKHAUS-96]

DICKHAUS, H.; HEINRICH, H. **Classifying Biosignals with Wavelet Networks** IEEE Engineering in Medicine and Biology, Setembro/Outubro, 1996.

[DUDA-73]

DUDA, R.O.; HART, P.E. **Pattern Classification and Scene Analysis,** John Wiley and Sons, 1973.

[EGAN-80]

EGAN, Robert L.; McSWEENWY, Marjorie B.; SEWELL, Charles W. **Intramammary Calcifications without an Associated Mass in Benign and Malignant Diseases,** Radiology, 137, p. 1-7, Outubro, 1980.

[EVANS-81]

EVANS, A. Li **The evaluation of medical images – Medical physics handbooks: 10** ISSN 0143-0203 – Ed. Adam Hilger Ltd., 1981.

[FAUSETT-94]

FAUSETT, L. **Fundamental of Neural Networks - Architectures, Algorithms, and Applications** Printice Hall International, Inc., 1994.

[FUKUNAGA-90]

FUKUNAGA, K. **Introduction to Statistical Pattern Recognition** Academic Press, Inc., Second Edition, 1990.

[GAL-84]

GAL, L.M.; CHAVANNE, G.; PELLIER, D. **Valeur diagnostique des microcalcifications groupées découvertes par mammographies** Bull Cancer, 71: 57-64, 1984.

[GONZALEZ-87]

GONZALEZ, R.C.; WINTZ, P. **Digital Image Processing**. Addison-Wesley Publishing Company, United States of America, 1987.

[GUPTA-87]

GUPTA, L. e SRINATH M. D. **Contour Sequence Moments for the Classification of Closed Planar Shapes**. Pattern Recognition, Vol. 20, Nro. 3, p. 267-272, 1987.

[HU-62]

HU, M.K.; **Visual pattern recognition by moment invariants** IRE Transactions on Information Theory IT-8, pp. 28-32, 1962.

[JIANG-94]

JIANG, Y.; NISHIKAWA, R. M.; WOLVERTON, D.E.; GIGER, M. L.; DOI, K.; SCHMIDT, R. A.; VYBORNY, C. J. **Mammographic Feature Analysis of Clustered Microcalcifications for Classification of Breast Cancer and Benign Breast Diseases** IEEE Transactions on Medical Imaging, pp. 594-595, Junho, 1994.

[JIANG-96]

JIANG, Y.; NISHIKAWA, R. M.; WOLVERTON, D.E.; METZ, C.E.; GIGER, M. L.; SCHMIDT, R. A.; VYBORNY, C. J.; DOI, K. **Malignant and Benign Clustered Microcalcifications: Automated Feature Analysis and Classification** Radiology, 198, p. 671-679, 1996.

[KADAH-96]

KADAH, Y.M.; FARAG, A. A.; ZURADA, J.M.; BADAWI, A.M.; YOUSSEF, A.M. **Classification Algorithms for Quantitative Tissue Characterization of Diffuse Liver Disease from Ultrasound Images** IEEE Transactions on Medical Imaging, Vol. 15, No.4, Agosto, 1996.

[KATSURAGAWA-88]

KATSURAGAWA, S.; DOI, K.; MACMAHON, H. **Image feature analysis and computer-aided diagnosis in digital radiography: Detection and characterization of interstitial disease in digital chest radiography** Medical Physics, Vol. 15, pp. 311-319, 1988.

[KOCUR-96]

KOCUR, C.M.; ROGERS, S.K.; MYERS, L.R.; BURNS, T.; KABRISKY, M.; HOFFMEISTER, J.W.; BAUER, K.W. e STEPPE, J.M. **Using Neural Networks to Select Wavelet Features for Breast Cancer Diagnosis** IEEE Engineering in Medicine and Biology, pp. 95-102, Maio/Junho, 1996.

[KULKARNI-94]

KULKARNI, A. D. **Artificial Neural Networks for Image Understanding** Van Nostrand Reinhold, New York, 1994.

[LAAKSONEN-96]

LAAKSONEN, Jorma; OJA, Erkki **Classification with Learning k-Nearest Neighbors**, Proceedings of ICNN'96, Washington, DC, p.1480-1483, Junho, 1996.

[LAINE-95]

LAINE, Andrew; FAN, Jian e YANG Wuhai **Wavelets for Contrast Enhancement of Digital Mammography**, IEEE Engineering in Medicine and Biology, p. 536-550, Setembro/Outubro, 1995.

[LEFEBVRE-94]

LEFEBVRE, Françoise; BENALI, Habib; GILLES, René e PAOLA, Robert Di A **simulation model of clustered breast microcalcifications**, Medical Physics, Vol. 21, p. 1865-1874, Dezembro, 1994.

[MAGNIN-89]

MAGNIN, I.E.; ALAOUI, M.El.; BRÉMOND, A. **Automatic microcalcifications pattern recognition from x-ray mammographies**, SPIE – Science and Engineering of Medical Imaging, Vol.1137, 1989.

[MARQUES-98]

MARQUES, M. A. **Simulação computacional de parâmetros importantes de sistemas radiológicos**, 156p, Tese (Doutorado) - Instituto de Física de São Carlos, Universidade de São Paulo, 1998.

[MASCARENHAS-89]

MASCARENHAS, N.D.A.; VELASCO, F.R.D. **Processamento Digital de Imagens** Editorial Kapelusz S.A., Buenos Aires, Argentina, 1989.

[MASTERS-89]

MASTERS, T. **Practical Neural Network Recipes in C++** Academic Press, Inc., ISBN 0-12-479040-2, 1993.

[MORROW-92]

MORROW, W.M.; PARANJAPE, R.B.; RANGAYYAN, R.M. e DESAUTELS, J.E.L. **Region-Based Contrast Enhancement of Mammograms** IEEE Transactions on Medical Imaging, Vol. 11, Nro. 3, Setembro, 1992.

[NETO-95]

NETO, U.M.B.; SIQUEIRA, W.A. **A Technique for the Automatic Detection and Classification of Mammographic Calcifications using the Watershed Method** Anais do VII SIBGRAPI, Outubro, 1995.

[NISHIKAWA-90]

NISHIKAWA, R. M.; GIGER, M. L.; DOI, K.; SCHMIDT, R. A.; VYBORNÝ, C. **J. Automated detection of microcalcifications on mammograms. New feature extraction techniques with morphologic filters** 76th Scientific Assembly and Annual Meeting of RSNA, Radiology 177(P), pp.288, 1990.

[NISHIKAWA-92]

NISHIKAWA, R.M.; JIANG, Y.; GIGER, M.L.; DOI, K.; VYBORNÝ, C.J.; SCHMIDT, R.A. **Computer-aided detection of agrupamentoed microcalcifications.** Proceedings of IEEE International Conference on Systems, Man and Cybernetics (Chicago),p. 1375-1378, 1992.

[NISHIKAWA-93A]

NISHIKAWA, R.M.; GIGER, M.L.; DOI,K.; VYBORNÝ, C.J.; SCHMIDT, R.A. **Computer-aided detection of agrupamentoed microcalcifications: an improved method for grouping detected signals.** Medical Physics, v. 20 (6), p. 1661-1666, 1993.



[NISHIKAWA-93B]

NISHIKAWA, R.M.; GIGER, M.L.; DOI, K.; VYBORNÝ, C.J.; SCHMIDT, R.A.  
**Computer-aided detection and diagnosis of masses and agrupamentoed microcalcifications from digital mammograms.** State of the Art in Digital Mammographic Image Analysis World Scientific Publishing Co. , 1993.

[PARKER-93]

PARKER, J.; DANCE, D.R.; DAVIES, D.H.; YEOMAN, L.J.; MICHELL, M.J.; HUMPHREYS, S. **Classification of Ductal Carcinoma In-Situ by image analysis of calcifications from mammograms** SPIE, Vol.1905, p. 832-840, Agosto, 1993.

[PARKER-94]

PARKER, J.; DANCE, D.R.; DAVIES, D.H. **Digital mammography: Image analysis and automatic classification of calcifications in ductal carcinoma in situ.** State of the Art in Digital Mammographic Image Analysis, World Scientific - New Jersey, pp.133-246, 1994.

[PATRICK-91]

PATRICK, Edward A.; MOSKOWITZ, Myron; MANSUKHANI, Vineet T. e GRUENSTEIN, Eric I. **Expert Learning System Network for Diagnosis of Breast Calcifications** Investigative Radiology, Vol.26, p.534-539, Junho, 1991.

[PEREIRA-95]

PEREIRA, A.S. **Processamento de Imagens Médicas utilizando a transformada de Hough** São Carlos, EESC/USP, 1995. Tese (doutoramento).

[PETRICK-96]

PETRICK, Nicholas; CHAN, Heang-Ping; SAHINER, Berkman; WEI, Datong **An Adaptive Density-Weighted Contrast Enhancement Filter for Mammographic Breast Mass Detection** IEEE Transactions on Medical Imaging, Vol. 15, p. 59-67, Nro. 1, Fevereiro, 1996.

[PETROSIAN-94]

PETROSIAN, A.; CHAN, H.-P.; HELVIE, M. A.; GOODSITT, Mitchell M. e ADLER, D.D. **Computer-aided diagnosis in mammography: classification of mass and normal tissue by texture analysis** Phys. Med. Biol., vol. 39, p. 2273-2289, 1994.

[PRECHELT-94]

PRECHELT, L. **PROBEN1 – A set of Neural Network Benchmark Problems and Benchmarking Rules** Technical Report 21/94, Fakultät für Informatik Universität Karlsruhe – Germany, Setembro, 1994.

[RICHARDSON-95]

RICHARDSON, Walter B.; **Applying Wavelets to Mammograms** IEEE Engineering in Medicine and Biology, p. 551-560, Setembro/Outubro, 1995.

[SHEN-93A]

SHEN, L.; RANGAYYAN, R.M.; DESAUTELS, J.E.L. **An automatic detection and classification system for calcifications in mammograms** SPIE v. 1905, p. 799-805, 1993.

[SHEN-93B]

SHEN, L.; RANGAYYAN, R.M.; DESAUTELS, J.E.L. **Detection and classification of mammographic calcifications** International Journal of Pattern Recognition and Artificial Intelligence, v. 7(6), p. 1403-1416, 1993.

[SHEN-94]

SHEN, L.; RANGAYYAN, R.M.; DESAUTELS, J.E. L. **Application of shape analysis to mammographic calcifications** IEEE Transactions on Medical Imaging, v. 13(2), p. 263-274. 1994.

[SPIESBERGER-79]

SPIESBERGER, W. **Mammogram inspection by computer** IEEE Transactions on Biomed. Eng. Vol.26, p.213-219, 1979.

[WEE-71]

WEE, W.G. **Generalized inverse approach to clustering, feature selection and classification** IEEE Trans. Inf. Theory, p.262-269, Maio 1971.

[WEE-75]

WEE, W.G.; MOSKOWITZ, M.; CHANG, W.C.; TING, Y.C.; PEMMERAJU, S. **Evaluation of Mammographic Calcifications Using a Computer Program** Radiology, vol. 110, p. 717-720, Setembro 1975.

[WOODS-94]

WOODS, K.S.; SOLKA, J.L.; PRIEBE, C.E.; Kegelmeyer, W. P.; **Comparative evaluation of pattern recognition techniques for detection of microcalcifications in Mammograms** State of the Art in Digital Mammographic Analysis, World Scientific - New Jersey, p. 841-852; 1994.

[WU-92]

WU, Y.; DOI, K; GIGER, M. L. ; NISHIKAWA R. M. **Computerized detection of clustered microcalcification in digital mammograms: Applications of artificial neural networks** Medical Physics, 19 (3) Maio/Junho 1992.

[WU-93]

WU, Y.; DOI, K; GIGER, M. L.; DOI, K.; VYBORNÝ, C.J.; SCHMIDT, R.A.; METZ, C.E. **Artificial Neural Networks in Mammography: Application to Decision Making in the Diagnosis of Breast Cancer** Radiology, Vol. 187, p.81-87, 1993.

[YABASHI-89]

YABASHI, SEIJI; HATA, MASAYASU, KUBO, KANJI; ISHIKAWA, TARO; **Extraction and Computational Estimation of Malignant Microcalcification on Mammography** Systems and Computers in Japan, Vol. 20, No. 12, 1989.

[ZHANG-94]

ZHANG, W.; DOI, K; GIGER ,M. L.; WU, Y.; NISHIKAWA R. M.; SCHMIDT, R.A. **Computerized detection of clustered microcalcification in digital mammograms using a shift-invariant artificial neural network** Med. Physics, 21 (4) April 1994.