**UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS
Departamento de Engenharia Elétrica**

**CLASSIFICAÇÃO POR ANÁLISE DE CONTORNOS DE
NÓDULOS MAMÁRIOS UTILIZANDO REDES NEURAIAS
ARTIFICIAIS**

Patricia Bellin Ribeiro

Monografia apresentada à Escola de Engenharia
de São Carlos da Universidade de São Paulo,
como parte dos requisitos para a obtenção do
título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Homero Schiabel

São Carlos
2006

Ficha catalográfica preparada pela Seção de Tratamento
da Informação do Serviço de Biblioteca – EESC/USP

R484c Ribeiro, Patricia Bellin
 Classificação por análise de contornos de nódulos
 mamários utilizando redes neurais artificiais / Patricia
 Bellin Ribeiro. -- São Carlos, 2006.

 Dissertação (Mestrado) -- Escola de Engenharia de São
 Carlos-Universidade de São Paulo, 2006.
 Área: Engenharia Elétrica.
 Orientador: Prof. Dr. Homero Schiabel.

 1. Redes neurais. 2. Classificação de contorno de
 nódulo. 3. Câncer de mama. 4. Mamografia. 5. Textura.
 I. Título.

FOLHA DE JULGAMENTO

Candidata: Tecnóloga **PATRICIA BELLIN RIBEIRO**

Dissertação defendida e julgada em 18-08-2006 perante a Comissão Julgadora:

Prof. Associado **HOMERO SCHIABEL (Orientador)**
(Escola de Engenharia de São Carlos/USP) **APROVADA**

Prof.^a Associada **ROSELI APARECIDA FRANCELIN ROMERO**
(Instituto de Ciências Matemáticas e de Computação/USP) **APROVADA**

Dr. **MARCO ANTONIO GUTIERREZ**
(Autônomo) **APROVADA**

Prof. Associado **HOMERO SCHIABEL**
Coordenador do Programa de Pós-Graduação em
em Engenharia Elétrica

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

Dedico...

Aos meus pais, José Urias e Vera Lucia, por todo
amor e carinho... que me deu forças para vencer
os obstáculos.

Ao meu irmãozinho, Paulo Eduardo, pela amizade
e por sempre estar perto de mim...

Ao meu marido, Rodrigo, para quem eu
entreguei meus sonhos, minha vida e todo meu amor.

Agradeço...

Aos meus pais José Urias e Vera Lucia, ao meu irmão Paulo Eduardo, aos meus avós Jacira e Eugenio (*in memória*), Alice e Urias (*in memória*), pelo amor que vocês me deram.

As minhas tias: Lia, Maria, Sandra (Tata), Silvia, Vanda, Estela, Luzia, Maria José e Tereza; aos meus tios: Beto, Carlos, Carlinho, Paulo, Nelson, Luiz, Manoel (*in memória*), Milton e a todos os meus primos e primas, que são muitos...em especial aos pequeninos Gabriel, Gabrielle e Camille.

Ao meu marido Rodrigo, por todo incentivo, carinho e compreensão... ao Sr. Domingos, D. Eurides, D. Maria, Regina, Valdira, Franco, Daniela, Letícia (minha amada afilhada, amiga e sobrinha) e a pequenina Julia.

As minhas amigas (de Bauru) queridas do coração Alessandra, Alexssandra, Geórgia, Helen, Jercília, Karina, Sabrina, nossa amizade é para todo sempre... Amo todas vocês!

Ao Colégio Técnico Industrial “Prof. Isaac Portal Roldan” (CTI - Unesp/Bauru), em especial aos diretores Edson e Carlos e aos coordenadores Júnior (eletrônica) e André Dalast (informática), por ceder três de seus laboratórios (total de 49 computadores) para a realização dos 3000 treinamentos realizados na 2ª. Fase dos Experimentos.

Ao amigo Julio Cesar Torelli, que desde o colegial (CTI - Unesp/Bauru) nos tornamos amigos para a eternidade...

As minhas amigas da FATEC Heleina, Marina, Raquel e Tathy por todos os brigadeiros e festas da Luluzinha na casa da Tathy e da Marina. Sinto muitas saudades, vocês são muito importantes para mim.

Ao Prof. Mts. Sebastião Gândara Vieira, pela competência a qual me orientou no TCC e por sempre torcer pelo meu sucesso.

Ao Prof. Dr. Olympio, pela pessoa especial, pela amizade e por todo carinho.

Ao Prof. Dr. João Fernando Marar, pelo dois anos de convívio no laboratório SACI (UNESP - Bauru) e por ter me ajudado nos primeiros passos na pesquisa com Redes Neurais Artificiais.

Ao meu orientador Prof. Dr. Homero Schiabel, pela confiança em meu trabalho e apoio nos momentos mais difíceis do desenvolvimento deste projeto.

À Profa. Dra. Roseli Ap. Francelin Romero, pelas dicas, amizade e prontidão ao me atender sempre.

À Profa. Dra. Ana Claudia Patrocínio, por tudo, pela amizade, convivência, ajuda, preocupação, pelos dias e noites de trabalho na sua casinha de São Carlos, pela minha primeira festa de Halloween, pelo final de semana em São Paulo...

À minha amiga Eveline Batista Rodrigues (agora também mestre), pelos dois anos que ficamos 24 horas juntas, já que fizemos mestrado no mesmo laboratório e moramos na mesma casa...pela amizade, pelas risadas, por todos os nossos jantares, pelos passeios...

À Paulitcha, Paula Simone Saia, pelas noites de bate papo, pelas risadas, brigadeiros...

Aos amigos do LAPIMO a Ana Martinez, por todas as dicas e carinho; a Vivian, minha querida Profa., por toda ajuda; ao Maurício, pelo coração imenso e por estar sempre pronto a ajudar; ao Marcelo (Mogi), pelas dicas e muitas risadas; ao Cláudio, pela amizade, risadas e pela folhinha que ele trouxe do Texas para mim; ao Leandro, meu querido amigo, pelas comidas que inventamos, pelas noites no laboratório e por muitas risadas; Carolina, Renata, Michele, Jr. e Fábio.

Aos professores e funcionários do Departamento de Engenharia Elétrica da EESC - USP, em especial para o Rui, Odair, Vera e ao Prof. Dr. Adilson Gonzaga. Vocês estarão para sempre em minha memória e no meu coração.

A todos os outros amigos que não possuem o nome escrito nestes agradecimentos mas que estão dentro do meu coração.

À CAPES pelo apoio financeiro.

A Deus, eu agradeço a todas as pessoas boas que conheci em minha vida e a todas as oportunidades a qual me deu saúde para conquistá-las.

RESUMO

RIBEIRO, P. B. (2006). *Classificação por Análise de Contornos de Nódulos Mamários Utilizando Redes Neurais Artificiais*. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2006.

Este trabalho apresenta a proposta de uma metodologia para classificação de nódulos mamários por contorno. O contorno do nódulo apresenta difícil interpretação pelos especialistas, devido à dificuldade de visualização e o baixo contraste das imagens mamográficas. As imagens utilizadas foram obtidas do banco de imagens mamográficas do LAPIMO, no total foram utilizadas 135 imagens contendo laudos por contorno. Através das imagens mamográficas digitalizadas são recortadas Região de Interesse (RI) de onde serão extraídos descritores de textura, intensidade e geométricos com o objetivo de caracterizar os padrões de contorno de nódulos. Após a extração desses descritores foram utilizados dois métodos de seleção de atributos, um utilizando Rede Neural *Self-Organizing Map* (SOM) e Gaussianas e outro utilizando Matriz de Covariância. Os atributos extraídos serviram de entrada para duas Redes Neurais a *Multi-Layer Perceptron* (MLP) e SOM, através do qual, foram realizados diversos treinamentos utilizando diferentes entradas, várias topologias e diferentes saídas, devido às várias combinações de classes. Dentre todos os treinamentos realizados, o treinamento escolhido para compor o Classificador Final foi o conjunto formado pelas 5 classes, obtido pela Rede Neural MLP com topologia de 20 neurônios de entrada, 40 neurônios na primeira camada intermediária, 20 neurônios na segunda camada intermediária e 5 neurônios na camada de saída, com taxa de aprendizagem igual a 0,9 e erro menor que 0,01, as 20 entradas foram selecionada através da Rede SOM e Gaussianas. O acerto obtido utilizando 135 RIs e pesos fixos foi de 89% de acerto total, Az igual a 0,98, falso negativo igual a 5% e falso positivo igual a 7%. O classificador apresentado nesse trabalho será acrescentado ao classificador já existente no esquema CAD em mamografia.

Palavras-chave: redes neurais, classificação, câncer de mama, mamografia, textura.

ABSTRACT

RIBEIRO, P. B. (2006). *Classification by Analysis of Contour of Mammary Masses Using Artificial Neural Networks*. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2006.

This work presents the proposal of a methodology for mammary nodules classification by their contour. The nodule boundary is hard to interpret due to the low contrast of the mammographic images. Images used in the tests obtained from the LAPIMO's database are 135 images, with information about the masses. From regions of interest (ROIs) selected in such images texture, intensity and geometric features were extracted in order to characterize the patterns of nodules contour. After the features extraction two methods of features selection, were used: one using Self-Organizing Map (SOM) neural networks together gaussian distributions analysis and another using Covariance Matrix. The extracted features were the input for two neural networks, a Multi-Layer Perceptron (MLP) and a SOM. Several trainings were accomplished using different inputs, several topologies and different exits, regarding several classes combinations. Among all of the trainings, the choice has corresponded to the group formed by 5 classes, obtained for the MLP neural networks in a topology of 20 input neurons, 40 neurons in the first intermediate layer, 20 neurons in the second intermediate layer and 5 neurons in the exit layer, with learning rate of 0.9 and error smaller than 0.01. The 20 inputs were selected by the SOM network together gaussian distributions. The performance using 135 ROIs and fixed weights has registered 89% of right responses with $A_z = 0.98$, false negative rate of 5% and false positive rate of 7%. The classifier presented in this work is being implemented in the general classifier as part of our group CAD scheme in mammography.

Keywords: neural networks, classification, breast cancer, mammography, texture.

LISTA DE FIGURAS

Figura 2.1	- Incidências mais utilizadas na mamografia.....	26
Figura 2.2	- Incidências que podem ser obtidas girando o mamógrafo.....	26
Figura 2.3	- Compartimento de compressão.....	27
Figura 2.4	- Microcalcificações da mama esquerda.....	29
Figura 2.5	- Nódulo denso e espiculado na mama direita.....	30
Figura 2.6	- A forma da massa pode ser dividida em cinco formas.....	31
Figura 2.7	- A margem da massa pode ser dividida em cinco contornos.....	31
Figura 3.1	- Esquema demonstrando os ângulos para obtenção da matriz SGLD a partir da imagem.....	36
Figura 3.2	- Cálculo da matriz de co-ocorrência.....	37
Figura 3.3	- Posição padrão para invariância à rotação.....	48
Figura 4.1	- Neurônio de McCulloch e Pitts.....	54
Figura 4.2	- Neurônio artificial completo.....	55
Figura 4.3	- Funções rampa e limite.....	56
Figura 4.4	- Função sigmóide.....	56
Figura 4.5	- Camadas de uma RNA genérica ou Rede Multicamadas.....	57
Figura 4.6	- Rede <i>Feedforward</i>	58
Figura 4.7	- Rede <i>FeedBack</i>	58
Figura 4.8	- Mapa de Kohonen.....	62
Figura 5.1	- Mamograma que contém uma massa benigna circunscrita.....	66
Figura 5.2	- Extração da normal, mostrado em linhas pretas a borda da massa benigna da Figura 5.1.....	66
Figura 5.3	- Tira ou faixa de <i>pixels</i> extraída pelo limite de massa benigna da Figura 5.1 é extraído pelo cálculo do gradiente e de características de textura.....	66
Figura 5.4	- Mamograma que contém uma massa maligna espicular.....	66
Figura 5.5	- Extração da normal, mostrado em linhas pretas a borda da massa maligna espicular da Figura 5.4.....	66
Figura 5.6	- Tira ou faixa de <i>pixels</i> extraída pelo limite de massa maligna da Figura 5.4 e extraída pelo cálculo do gradiente e de características de textura.....	66
Figura 5.7	- Um mamograma com um tumor espicular maligno.....	68
Figura 5.8	- O mapa de contornos de isso-intensidade extraiu do mamograma mostrado na Figura 5.7 o contorno da mama descoberto.....	68
Figura 5.9	- Extração do sinal da distancia radial.....	70
Figura 5.10	- Sub-regiões de amostra de esquemas sob várias vizinhanças de <i>pixel</i> de: (a) $d=1$, (b) $d=2$ e (c) $d=3$	72
Figura 5.11	- Interferência entre as duas curvas de distribuição normais à probabilidade de erro estatística devido a <i>aliasing</i> entre as duas classes. O verdadeiro erro de <i>aliasing</i> era calculado aplicando o limiar de decisão específico para indicador de limite de borda no grupo de 130 imagens mamográficas.....	78
Figura 6.1	- Interface para extração de atributos de Haralick.....	83

Figura 6.2	- Interface de extração de atributos de intensidade.....	84
Figura 6.3	- Imagem com as linhas de <i>Watershed</i> e junção com a imagem original.....	86
Figura 6.4	- Imagem segmentada e seu contorno.....	86
Figura 6.5	- Interface de extração de atributos geométricos.....	87
Figura 6.6	- Interface utilizada para a extração de todos os atributos e que foi adaptada para a construção da tela do classificador final.....	88
Figura 6.7	- Mapa Auto-Organizável de Kohonen.....	89
Figura 6.8	- <i>Multi-Layer Perceptron</i> (MLP).....	90
Figura 6.9	- Banco de Imagens Mamograficas.....	91
Figura 6.10	- Distribuição Gaussiana sem a sobreposição das curvas.....	92
Figura 6.11	- Distribuição Gaussiana com sobreposição completa das curvas.....	92
Figura 7.1	- Exemplo de RIs com nódulos, utilizadas para os testes iniciais.....	97
Figura 7.2	- Exemplo de RIs normais, utilizadas para os testes iniciais.....	97
Figura 7.3	- Esquema de classificação.....	98
Figura 7.4	- <i>Clusters</i> do primeiro experimento.....	99
Figura 7.5	- Algumas distribuições Gaussianas dos atributos de textura que não produziram bons resultados.....	100
Figura 7.6	- Seis distribuições Gaussianas dos atributos de textura que produziram bons resultados.....	101
Figura 7.7	- <i>Clusters</i> do Experimento 3.....	102
Figura 7.8	- Exemplo de RIs utilizadas para os testes, representando cada uma das cinco classes de contorno.....	107
Figura 7.9	- Curvas ROC dos resultados dos treinamentos realizados com a Rede MLP (Tabela 7.6).....	111
Figura 7.10	- Curvas ROC dos resultados dos treinamentos realizados com a Rede SOM (Tabela 7.6).....	111
Figura 7.11	- Mapa da Rede SOM e Distribuição Gaussiana - Atributo de Textura: Contraste.....	113
Figura 7.12	- Mapa da Rede SOM e Distribuição Gaussiana - Atributo de Textura: Entropia da Diferença.....	114
Figura 7.13	- Mapa da Rede SOM e Distribuição Gaussiana - Atributo de Textura: Entropia da Soma.....	114
Figura 7.14	- Mapa da Rede SOM e Distribuição Gaussiana - Atributo de Textura: Momento da Diferença Inversa.....	114
Figura 7.15	- Mapa da Rede SOM e Distribuição Gaussiana - Atributo de Textura: Média da Soma.....	115
Figura 7.16	- Mapa da Rede SOM e Distribuição Gaussiana - Atributo de Textura: Variância.....	115
Figura 7.17	- Mapa da Rede SOM e Distribuição Gaussiana - Atributo de Textura: Entropia da Diferença.....	116
Figura 7.18	- Mapa da Rede SOM e Distribuição Gaussiana - Atributo de Textura: Entropia da Soma.....	116
Figura 7.19	- Mapa da Rede SOM e Distribuição Gaussiana - Atributo de Textura: Variância.....	116
Figura 7.20	- Curvas ROC dos resultados dos treinamentos realizados com a Rede MLP (Tabela 7.9).....	119
Figura 7.21	- Curvas ROC dos resultados dos treinamentos realizados com a Rede SOM (Tabela 7.9).....	119
Figura 7.22	- Curvas ROC dos resultados dos treinamentos realizados com a Rede MLP (Tabela 7.12).....	121

Figura 7.23 - Curvas ROC dos resultados dos treinamentos realizados com a Rede SOM (Tabela 7.12).....	122
Figura 7.24 - Curvas ROC dos resultados dos treinamentos realizados com a Rede MLP (Tabela 7.15).....	125
Figura 7.25 - Curvas ROC dos resultados dos treinamentos realizados com a Rede SOM (Tabela 7.15).	126
Figura 7.26 - Curvas ROC dos resultados dos treinamentos realizados com a Rede MLP (Tabela 7.18).....	128
Figura 7.27 - Curvas ROC dos resultados dos treinamentos realizados com a Rede SOM (Tabela 7.18).....	128
Figura 7.28 - Curvas ROC dos resultados dos testes, com pesos fixos, realizados com o classificador final (Tabela 7.24).....	131
Figura 7.29 - Curvas ROC dos resultados dos testes, com pesos fixos, realizados com o classificador final (Tabela 7.26).....	132
Figura 7.30 - Classificação do contorno Circunscrito.....	133
Figura 7.31 - Classificação do contorno Obscurecido.....	133
Figura 7.32 - Classificação do contorno Microlobulado.....	133
Figura 7.33 - Classificação do contorno Mal Definido.....	133
Figura 7.34 - Classificação do contorno Espiculado.....	134
Figura 7.35 - Classificador de contornos de nódulos mamários.....	134

LISTA DE TABELAS

Tabela 2.1 - Classificação morfológica.....	29
Tabela 2.2 - Categoria BI-RADS® quarta edição.....	33
Tabela 3.1 - Interpretação geométrica dos momentos centrais de segunda e terceira ordem.....	49
Tabela 5.1 - Precisões de classificação para algumas combinações de características de forma em termos da área sob a curva de ROC.....	77
Tabela 5.2 - Taxa de Sucesso de todos os classificadores CAD, com e sem contribuição de tipo de forma.....	79
Tabela 7.1 - Resumo das duas fases de Experimento.....	96
Tabela 7.2 - Resultados da MLP, tendo como entrada todos os atributos de textura.	104
Tabela 7.3 - Resultados da MLP, tendo como entrada 6 atributos de textura selecionado pelas Gaussianas.....	105
Tabela 7.4 - Levantamento de imagens laudadas por contorno (HC - UNESP/Botucatu).....	106
Tabela 7.5 - Levantamento de imagens laudadas por contorno (HC - FMRP/USP).....	106
Tabela 7.6 - Treinamentos realizados com todos os atributos.....	109
Tabela 7.7 - Topologias utilizadas pela Rede Neural MLP.....	109
Tabela 7.8 - Topologias utilizadas pela Rede Neural SOM.....	109
Tabela 7.9 - Treinamentos realizados com 20 atributos selecionados pela Rede Neural SOM e Gaussianas.....	117
Tabela 7.10 - Topologias utilizadas pela Rede Neural MLP.....	117
Tabela 7.11 - Topologias utilizadas pela Rede Neural SOM.....	117
Tabela 7.12 - Treinamentos realizados com sete atributos selecionados pela Rede Neural SOM e Gaussianas.....	120
Tabela 7.13 - Topologias utilizadas pela Rede Neural MLP.....	120
Tabela 7.14 - Topologias utilizadas pela Rede Neural SOM.....	121
Tabela 7.15 - Treinamentos realizados com 21 atributos selecionados pela Matriz de Covariância.....	124
Tabela 7.16 - Topologias utilizadas pela Rede Neural MLP.....	124
Tabela 7.17 - Topologias utilizadas pela Rede Neural SOM.....	124
Tabela 7.18 - Treinamentos realizados com 9 atributos selecionados pela Matriz de Covariância.....	126
Tabela 7.19 - Topologias utilizadas pela Rede Neural MLP.....	127
Tabela 7.20 - Topologias utilizadas pela Rede Neural SOM.....	127
Tabela 7.21 - Melhores resultados de todos os treinamentos.....	129
Tabela 7.22 - Topologia dos melhores resultados de todos os treinamentos.....	129
Tabela 7.23 - Testes percentuais realizados com o classificador final, utilizando 110 imagens.....	130
Tabela 7.24 - Testes realizados com o classificador final, utilizando 110 imagens.....	130
Tabela 7.25 - Testes percentuais realizados com o classificador final, utilizando 135 imagens.....	132
Tabela 7.26 - Testes realizados com o classificador final, utilizando 135 imagens.....	132

SUMÁRIO

RESUMO

ABSTRACT

LISTA DE FIGURAS

LISTA DE TABELAS

1 - INTRODUÇÃO.....	21
1.1 - O Câncer de Mama e as Ferramentas de Auxílio ao Diagnóstico.....	21
1.2 - Motivação.....	23
1.3 - Objetivos.....	23
1.4 - Disposição do Trabalho.....	24
2 - A IMAGEM MAMOGRÁFICA.....	25
2.1 - Lesões Detectadas na Mamografia.....	28
2.1.1 - Nódulos.....	30
2.2 - Classificação Radiológica.....	32
3 - MÉTODOS DE EXTRAÇÃO DE ATRIBUTOS APLICADOS A IMAGEM MÉDICA.....	35
3.1 - Descritores de Textura.....	35
3.2 - Descritores de Intensidade.....	41
3.3 - Descritores Geométricos.....	44
3.3.1 - A Teoria dos Momentos.....	44
3.3.1.1 - Os Momentos Invariantes de Hu.....	46
3.3.2 - Outros Atributos de Forma.....	50
3.4 - Conclusão.....	51
4 - A INTELIGÊNCIA ARTIFICIAL E AS REDES NEURAI ARTIFICIAIS.	53
4.1 - Redes Neurais Artificiais.....	54
4.1.1 - Arquiteturas de Redes Neurais Artificiais.....	57
4.1.2 - Aprendizagem.....	58
4.2 - Rede <i>Multi-Layer Perceptron</i>	59
4.3 - Rede <i>Self-Organizing Map</i>	62
4.4 - Conclusão.....	64
5 - CLASSIFICADORES AUTOMÁTICOS EM ESQUEMAS CADs.....	65

6 - MATERIAIS E MÉTODOS.....	81
6.1 - Extração de Atributos.....	81
6.1.1 - Descritores de Textura de Haralick.....	82
6.1.2 - Descritores de Intensidade.....	83
6.1.3 - Descritores Geométricos.....	85
6.1.4 - Utilização de Todos os Descritores.....	87
6.2 - Redes Neurais Artificiais.....	88
6.3 - A Base de Imagens Mamográficas.....	91
6.4 - Análise de Atributos.....	92
7 - RESULTADOS E DISCUSSÕES.....	95
7.1 - 1ª Fase dos Experimentos.....	97
7.1.1 - Experimento 1: Extração de todos os Descritores de Textura e Classificação através da Rede Neural SOM para Validação do Algoritmo SOM.....	98
7.1.2 - Experimento 2: Utilização de Gaussianas para a seleção dos Melhores Atributos.....	99
7.1.3 - Experimento 3: Utilização dos 6 Atributos de Textura selecionados pelas Gaussianas e Classificação através da Rede Neural SOM.....	102
7.1.4 - Experimento 4: Extração de todos os Descritores de Textura e Classificação através da Rede Neural MLP.....	103
7.1.5 - Experimento 5: Utilização dos 6 Atributos de Textura selecionados pelas Gaussianas e Classificação através da Rede Neural MLP.....	104
7.1.6 - Conclusões.....	105
7.2 - 2ª Fase dos Experimentos.....	106
7.2.1 - Experimento 1: Extração de todos os Descritores e Classificação através das Redes Neurais MLP e SOM.....	107
7.2.2 - Experimento 2: Utilização da Rede Neural SOM e Gaussianas para a seleção dos Melhores Atributos.....	112
7.2.3 - Experimento 3: Utilização dos atributos selecionados por SOM e Gaussianas como entrada para as Redes Neurais MLP e SOM.....	117
7.2.4 - Experimento 4: Utilização de Matriz de Covariância para a Seleção de atributos.....	122
7.2.5 - Experimento 5: Utilização dos atributos selecionados pela Matriz de Covariância como entrada para as Redes Neurais MLP e SOM.....	123
7.2.6 - Experimento 6: Classificador Final.....	129
7.2.7 - Conclusões.....	135
8 - CONCLUSÕES.....	137
8.1 - Trabalhos Futuros.....	139
REFERÊNCIAS BIBLIOGRÁFICAS.....	141

1 - INTRODUÇÃO

Há décadas pesquisas relacionadas ao câncer de mama, que possui índices altíssimos de mortalidade (Mavroforakis *et al.*, 2005), vêm sendo desenvolvidas com o objetivo de prolongar ou poupar muitas vidas. Devido aos esforços da ciência e o apoio da tecnologia, novas ferramentas de auxílio ao diagnóstico estão sendo desenvolvidas para a prevenção e detecção precoce do câncer de mama.

1.1 - O Câncer de Mama e as Ferramentas de Auxílio ao Diagnóstico

O câncer de mama é o que mais mata mulheres no Brasil, além de ser o mais temido pelas mulheres devido à sua alta frequência e, sobretudo, pelos seus efeitos psicológicos, que afetam a percepção da sexualidade e a própria imagem pessoal. Como suas causas ainda não são bem conhecidas, a prevenção é a única maneira de reduzir a mortalidade de mulheres com câncer de mama, pois a detecção precoce aumenta as chances de cura substancialmente (Mudigonda *et al.* 2000; Ball *et al.*, 2004; Mavroforakis *et al.*, 2005).

O avanço do diagnóstico precoce do câncer de mama (Sterns, 1996) se deu através do desenvolvimento de tecnologias – como a mamografia, a ultra-sonografia e a ressonância magnética – e de técnicas como: punção biópsia, a estereotaxia (procedimento intervencionista realizado com um sistema computadorizado, acoplado ao mamógrafo para orientar com agulha a localização pré-operatória de áreas suspeitas) para a marcação de nódulos ou áreas de microcalcificações (Heywang-Köbrunner *et al.*, 1999; Kopans, 2000; Gomes *et al.*, 2002).

Segundo a Organização Mundial Saúde (OMS), anualmente, cerca de um milhão de mulheres, em todo o mundo, descobre que está com câncer de mama. No Brasil, segundo o INCA¹, o número de novos casos de câncer de mama esperados para o Brasil em 2006 é de 48.930, sendo este o segundo tipo de câncer de maior incidência no país.

Atualmente, o Ministério da Saúde e o INCA estão mudando o enfoque central das campanhas de prevenção do câncer de mama, com a meta de reduzir em 20% as mortes. A nova proposta, que está sendo aplicada ao serviço público, é que todas as mulheres acima de 50 anos façam a mamografia a cada dois anos e se submetam ao exame clínico anualmente. As que tenham histórico familiar da doença devem fazer a mamografia todos os anos, a partir dos 35 anos. O auto-exame continuará sendo estimulado por três razões: pode detectar o câncer em mulheres fora da faixa etária de risco, descobrir outras doenças benignas da mama, mas que precisam de tratamento, e ajudar mulheres que não têm acesso ao serviço de saúde a descobrir os tumores, ainda que em fase mais avançada (INCA¹).

No auto-exame, são detectados nódulos a partir de 1,5 cm a 2 cm. Já a mamografia pode diagnosticar tumores malignos ou benignos com só 1 mm, quando as chances de cura são de 95%. Por isso, a mamografia por raios X é considerado o exame de maior sensibilidade para o rastreamento do câncer de mama (Heywang-Köbrunner *et al.*, 1999; Kopans, 2000; Ball *et al.*, 2004; Bilska-Wolak *et al.*, 2005).

Com o objetivo de auxiliar no diagnóstico de achados mamográficos, diversos trabalhos utilizando técnicas de Processamento de Imagens, Reconhecimento de Padrões, Visão Computacional e Inteligência Artificial vêm sendo desenvolvidos, como parte de esquemas CAD (*Computer Aided Diagnosis*), buscando melhorar a visibilização de imagens radiográficas por meios computacionais para auxiliar radiologistas na detecção de lesões (Doi *et al.*, 1995; Giger, 1999; Arbach *et al.*, 2003; Ball *et al.*, 2004; Patrocinio *et al.* 2004a; Zheng *et al.*, 2004; Zwiggelaar *et al.*, 2004). Os esquemas CAD utilizam imagens digitais, sendo, na maioria das vezes, os filmes mamográficos digitalizados com equipamentos de alta resolução seguindo técnicas específicas, junto com informações do paciente. A partir da localização de padrões anormais através da varredura da imagem pelo computador, e da quantificação de características da imagem, essas informações serão enviadas para um sistema classificador que poderão classificar as imagens em normais ou anormais. Tais esquemas podem funcionar como uma segunda opinião aos radiologistas quanto à

¹Fonte: INCA (Instituto Nacional de Câncer). Disponível em: <<http://www.inca.gov.br>>. Acessado em: 11/05/2006.

localização e à natureza destas estruturas (Doi *et al.*, 1995, 1997, 1999; Giger, 1999; Velthuizen, 2000).

1.2 - Motivação

Distorções na interpretação e classificação de lesões suspeitas por especialistas implicam um número maior de biópsias desnecessárias (Burrell *et al.*, 1996; Mudigonda *et al.*, 2000; Bilska-Wolak *et al.*, 2005; Mavroforakis *et al.*, 2005). Ou seja, entre 65% a 85% das biópsias de mama são realizadas em lesões benignas (Meyer *et al.*, 1990; Kopans, 1992). Com isso, diminui a relação custo-benefício dos exames e, no pior caso, a possibilidade de que a doença deixe de ser detectada, caracterizando os diagnósticos falsos negativos. A interpretação de lesões em um mamograma é uma tarefa complexa para os especialistas, de cuja experiência depende um diagnóstico preciso (Ball *et al.*, 2004).

Além da complexidade na interpretação de lesões em um mamograma, a imagem mamográfica possui baixo contraste e diversos fatores influenciam a sua qualidade, tais como: calibração do equipamento mamográfico, condições de revelação, conservação e manipulação do filme, composição do parênquima mamário e, nas imagens digitais, os fatores da digitalização.

Devido à complexidade de interpretação das lesões, o grupo do Laboratório LAPIMO (Laboratório de Análise e Processamento de Imagens Médicas e Odontológicas) vem desenvolvendo pesquisas há alguns anos com o objetivo de avaliar a qualidade e processamento de imagens mamográficas e na elaboração de um esquema CAD em mamografia, visando auxiliar os especialistas no diagnóstico de eventuais lesões.

1.3 - Objetivos

As Redes Neurais Artificiais (RNA) são freqüentemente usadas como classificadores em esquemas CAD (Bilska-Wolak *et al.*, 2005), e seu desempenho depende de vários estágios anteriores ao processo de classificação da lesão, sendo os principais: a aquisição do padrão, fundamental para o desempenho dos sistemas de reconhecimento

visual, e a extração e seleção de atributos que melhor representam cada classe (Duda *et al.*, 1973; Duda *et al.*, 1979).

Este trabalho tem como objetivo o desenvolvimento de um módulo classificador, que utiliza técnicas de extração e seleção de características e Redes Neurais Artificiais para classificar imagens de nódulo através de seu contorno, utilizando como base características em comuns que representem a diversidade de contornos descritas nos laudos radiográficos.

1.4 - Disposição do Trabalho

Além deste capítulo o trabalho está composto de mais 6 capítulos, conforme descrição sumária abaixo:

Capítulo 2: A Imagem Mamográfica - Aborda informações sobre o equipamento mamográfico, os conceitos sobre a mamografia, a importância do exame para a detecção precoce do câncer de mama, o que se procura ao analisar uma mamografia e sobre a imagem mamográfica digital.

Capítulo 3: Extração de Atributos - Descrições de técnicas utilizadas para a extração, análise de característica e a seleção de atributos que melhor representam cada classe a serem classificadas.

Capítulo 4: A Inteligência Artificial e as Redes Neurais Artificiais - Histórico e conceitos sobre as Redes Neurais Artificiais.

Capítulo 5: Classificadores em Esquemas CADs - Levantamento das aplicações na classificação automática de esquemas CAD.

Capítulo 6: Materiais e Métodos - Descrição dos materiais utilizados e detalhamento da metodologia aplicada.

Capítulo 7: Resultados e Discussões - Trata da apresentação dos resultados obtidos, avaliados através de curvas ROC, discussões e conclusões.

Capítulo 8: Conclusões - Conclusões finais sobre o trabalho.

Referências Bibliográficas - Bibliografia utilizada e consultada no decorrer do desenvolvimento do trabalho.

2 - A IMAGEM MAMOGRÁFICA

O exame mamográfico possui alta sensibilidade (Mudigonda *et al.*, 2000; Mudigonda *et al.*, 2001), apesar dos estudos evidenciarem perdas entre 10% a 15% dos casos de câncer com tumor detectável ao exame clínico (Kopans, 2000). Porém, esta sensibilidade está diretamente relacionada à idade da mulher, sendo muito menor nas mulheres jovens, que apresentam uma alta densidade de tecido mamário (ou seja, a mama é composta basicamente por tecidos fibroglandulares) ou em mulheres que fazem terapia de reposição hormonal (TRH), que pode manter por mais tempo a alta densidade radiográfica de tecidos, podendo dificultar a visibilização de estruturas suspeitas em imagens mamográficas (Heywang-Köbrunner *et al.*, 1999; Kopans, 2000).

A mamografia é uma das melhores técnicas para detecção do câncer de mama (Ball *et al.*, 2004) reduzindo a mortalidade entre 30% a 70%, sendo que até o momento essas porcentagens não foram alcançadas pelo diagnóstico clínico nem por meio de qualquer terapia medicamentosa. Além de ser o único método de imagem apropriado para um rastreamento, tendo boa sensibilidade e especificidade aceitável, fornecendo ainda a vantagem de ser um método não-invasivo, com alta capacidade de reprodução e de documentação e ocupa um tempo relativamente curto do médico executante (Heywang-Köbrunner *et al.*, 1999).

Com base no conhecimento da anatomia e mobilidade mamária, os equipamentos atualmente utilizam técnicas de posicionamento para que se possa explorar melhor a mama, sendo as mais utilizadas a incidência Médio-Lateral Obliqua (MLO), que oferece a melhor oportunidade de mostrar toda a mama numa única imagem, e a incidência Crânio-Caudal (CC), que complementa a MLO, incluindo todo o tecido pósterio-medial, o que não é possível na visibilização na MLO, Figura 2.1. Além dessas incidências existem

outras que podem ser obtidas girando o mamógrafo de modo que o feixe venha de qualquer direção: Médio-Lateral (ML), Ínfero-Superior Oblíqua (ISO), de Baixo (DB), Lateromedial Oblíqua (LMO), Lateromedial (LM) ou Súpero-Inferior Oblíqua (SIO) (Kopans, 2000), Figura 2.2.

Figura 2.1 - Incidências mais utilizadas na mamografia (Kopans, 2000).

a) Mamografia com projeção Médio-Lateral Oblíquo (MLO); b) Diagrama esquemático que indica a visualização do peitoral maior na incidência MLO ao nível da linha do eixo mamilar (LEM); c) Imagem resultante da mamografia com projeção MLO; d) Mamografia com projeção crânio-caudal (CC); e) Diagrama esquemático, onde, a linha correspondente do mamilo até a parte posterior do filme na projeção (CC). Esta linha deve ser mais de 1 cm mais curta do que a da LEM na projeção MLO; f) Imagem resultante da mamografia com projeção CC.

Figura 2.2 - Incidências que podem ser obtidas girando o mamógrafo, sendo elas: Crânio-Caudal (CC), Médio-Lateral Oblíqua (MLO), Médio-Lateral (ML), Ínfero-Superior Oblíqua (ISO), De Baixo (DB), Lateromedial Oblíqua (LMO), Lateromedial (LM), Súpero-Inferior Oblíqua (SIO).

O equipamento mamográfico utiliza um tubo gerador de raios X que é formado basicamente por dois eletrodos que recebem uma tensão, na ordem de milhares de *volts*, de forma a gerar um campo elétrico. O eletrodo negativo, catodo, quando aquecido pela passagem de uma corrente elétrica, libera elétrons que são acelerados pelo campo elétrico até colidirem com o eletrodo positivo, anodo, gerando um feixe de elétrons. A extremidade do anodo, onde os elétrons colidem, é revestida por um metal pesado, por exemplo, molibdênio e é chamada de alvo. Na colisão, aproximadamente 0,1%, é convertido em raios X, e o restante é dissipado na forma de calor. A pequena área do alvo onde o feixe de elétrons incide, é chamado ponto focal, que é um fator determinante na capacidade de resolução do equipamento mamográfico, onde, quanto menor o tamanho do ponto focal, melhor a resolução espacial do sistema de imagem. Para se conseguir um contraste adequado nas imagens de mama, os mamógrafos operam numa faixa mais baixa de tensão do que os equipamentos convencionais, com valores usuais entre 20 e 35 Kvp enquanto os equipamentos de raios X convencionais operam, geralmente, na faixa de tensão entre 40 e 120 kvp (Curry III *et al.*, 1990; Wolbarst, 1993).

Além dos dispositivos comuns aos aparelhos convencionais de radiografia, o mamógrafo possui um compartimento de compressão de acrílico com a finalidade de comprimir a mama. Essa compressão da mama contribui para a qualidade da imagem, pois garante imobilidade da paciente durante o exame, redução da espessura da mama, diminuindo a dose absorvida e o espalhamento dos fótons de raios X no filme. Isso reduz o ruído da imagem e diminui a sobreposição de imagens das estruturas internas da mama, permitindo que lesões suspeitas sejam detectadas com mais facilidade e segurança (Curry III *et al.*, 1990; Wolbarst, 1993), Figura 2.3.

Figura 2.3 - Compartimento de compressão. a) Compressão da mama durante a mamografia b) A compressão permite que lesões suspeitas sejam detectadas com facilidade.

Outros dispositivos do mamógrafo são: o colimador que é utilizado para evitar a radiação ionizante em outras partes do corpo da paciente e também colabora na melhoria da imagem, e o chassi mamográfico, que apresenta um écran intensificador que se posiciona sob o filme (Wolbarst, 1993).

A imagem mamográfica digital surgiu no final da década de 80 (Nishikawa *et al.*, 1987), porém, apenas em 2000 o primeiro equipamento mamográfico digital foi aprovado pelo departamento de saúde Norte Americano, *Food and Drug Administration* (FDA)². Este equipamento é semelhante ao aparelho mamográfico convencional, com exceção do sistema de registro, onde o filme e o écran são substituídos por sensores que absorvem a energia e a convertem em sinais elétricos que, transformados em pulsos digitais, serão manipulados para a extração de informações. A imagem digitalizada, seja proveniente do mamógrafo digital ou da digitalização do filme mamográfico através de *scanners*, é composta por *pixels* (*picture elements*) que é a unidade básica que constitui a imagem digital. Essas imagens devem possuir resolução espacial geralmente de 300 a 600 DPI (pontos por polegada), e resolução de contraste com uma quantidade de níveis de cinza suficiente para representar as diferenças entre os tecidos e estruturas presentes na imagem, geralmente 10 a 12 bits (Doi *et al.*, 1995). Atualmente no mercado, existem equipamentos com até 14 bits³.

2.1 - Lesões Detectadas na Mamografia

O diagnóstico seria simples se todos os cânceres de mama exibissem características singulares. Porém, embora tenham características específicas, há algumas similaridades inevitáveis entre forma, margens e densidade de muitas lesões benignas e malignas. Os tipos de lesões que aparecem com maior frequência nas mamografias são as microcalcificações e os nódulos (Kopans, 2000).

As microcalcificações, Figura 2.4, são os achados mamográficos encontrados entre 30% a 40% dos casos de câncer em lesões não palpáveis. Podem representar o sinal mais precoce de malignidade (Heywang-Köbrunner *et al.*, 1999; Kopans, 2000).

²Fonte: FDA (Food and Drug Administration - EUA). Disponível em: <<http://www.fda.gov>>. Acessado em: 14/06/2005.

³Fonte: UMAX. Disponível em: <<http://www.umax.com>>. Acessado em: 13/09/2005.

Figura 2.4 - Microcalcificações da mama esquerda

A análise das microcalcificações deve incluir algumas observações importantes como:

- 1 - **Tamanho:** são estruturas com tamanho igual ou menor que 0,5 mm; partículas pequenas sugerem malignidade e partículas maiores são mais sugestivas de benignidade;
- 2 - **Número:** quanto maior o número de microcalcificações por centímetro cúbico, maior a suspeita para malignidade;
- 3 - **Forma:** quanto maior a variedade de formas (puntiiformes, lineares, ramificadas), maior o grau de suspeita para malignidade, Tabela 2.1;

Tabela 2.1 - Classificação morfológica (Mitchell Jr.& Basset, 1988).

TIPO	MICROCALCIFICAÇÕES – MORFOLOGIA	% de malignidade
TIPO I	anulares, redondas, discóides, com centro luzente	todas são benignas
TIPO II	redondas, isodensas, uniformes	22% são malignas
TIPO III	puntiiformes, tipo “poeira”, difícil identificação	40% são malignas
TIPO IV	irregulares, poliédricas, tipo “grão de sal”	66% são malignas
TIPO V	vermiculares, ramificadas, em forma de letras	todas são malignas

- 4 - **Densidade:** as microcalcificações tipicamente malignas apresentam densidade alta e importante variação de densidade dentro das partículas e entre as

partículas. Portanto, densidade baixa e pouca ou nenhuma variação de densidade entre as partículas sugerem benignidade;

5 - **Distribuição:** as microcalcificações suspeitas de malignidade são em geral unilaterais, podem estar agrupadas num pequeno setor mamário ou dispostas em trajeto ductal.

2.1.1 - Nódulos

Os nódulos, Figura 2.5, são os achados mamográficos encontrados em 39% dos casos de câncer não palpáveis (Kopans, 2000).

Figura 2.5 - Nódulo denso e espiculado na mama direita.

A análise dos nódulos deve incluir algumas observações importantes como:

1 - **Tamanho:** no caso das lesões não palpáveis, este parâmetro é de importância relativa, pois os nódulos diagnosticados apenas pela mamografia, normalmente apresentam pequenas dimensões;

2 - **Forma:** os nódulos podem apresentar forma regular, lobulada, irregular e espiculada, Figura 2.6. A suspeita de malignidade aumenta em função da ordem citada acima;

Figura 2.6 - A forma da massa pode ser dividida em cinco formas (Kopans, 2000).

3 - **Margem:** representa a relação do nódulo com as estruturas vizinhas; portanto, limites mal definidos são mais sugestivos para malignidade (Mudigonda *et al.*, 2001) do que limites parcialmente definidos, Figura 2.7;

4 - **Densidade:** os nódulos malignos geralmente apresentam densidade elevada, às vezes densidade intermediária e raramente baixa densidade.

Figura 2.7 - A margem da massa pode ser dividida em cinco contornos (Kopans, 2000).

Segundo Kopans (Kopans, 2000) a margem entre uma lesão e o tecido circunvizinho, Figura 2.7, é um dos fatores mais importantes na determinação da benignidade ou malignidade de uma massa. As margens da massa segundo a *American College of Radiology* e o Colégio Brasileiro de Radiologia (CBR), podem ser divididas em cinco contornos:

Massas **circunscritas**, cujas margens formam uma transição nítida com o tecido circunvizinho, são quase sempre benignas. Uma vez que algumas lesões com margens mal definidas parecem ser circunscritas a uma resolução baixa, pode ser valioso

obter imagens com magnificação cujo ruído reduzido e nitidez melhorada podem aumentar a confiança da circunscrição ou revelar uma margem bem menos definida, que deve aumentar a preocupação.

Uma margem **obscurecida** ocorre quando o tecido circunvizinho normal esconde a borda verdadeira da lesão. O interpretador deve decidir se a margem de uma lesão está obscurecida ou verdadeiramente mal definida devido à infiltração. Esta última aumenta o nível de preocupação.

A margem **microlobulada** reflete a superfície irregular que pode ser produzida por um câncer de mama, embora os fibroadenomas e os cistos possam ter margem microlobulada. As saliências irregulares que nascem na borda de um tumor podem formar ondulações curtas na superfície da lesão quando visibilizada na mamografia. Elas são distintas de uma massa lobulada cujas ondulações são grandes.

A vasta maioria de cânceres de mama tem uma interface irregular à medida que eles invadem os tecidos circunvizinhos. Isto produz a margem verdadeiramente **mal definida** que deve gerar preocupação. A probabilidade de neoplasia maligna é elevada nas lesões com margens mal definidas devida ao confinamento de tecidos normais ou, no caso dos cistos, à inflamação pericística.

O câncer de mama clássico tem uma margem **espiculada** devida às projeções fibrosas que se estendem da massa principal do tumor. A etiologia exata da espiculação é incerta.

Esse tipo de classificação é muito complexa para o radiologista, por isso, estudos vêm sendo desenvolvidos para auxiliar esse especialista no diagnóstico do câncer de mama (Mudigonda *et al.*, 2001; Bottigli & Golosio, 2002).

2.2 - Classificação Radiológica

Um estudo colaborativo realizado por membros de vários comitês do *American College of Radiology* (ACR), com a colaboração do *American Medical Association*, *American College of Surgeons*, *Centers for Disease Control and Prevention*, *College of American Pathologists*, *College of Surgeons*, *Food and Drug Administration* e o *National Cancer Institute*, em 1992, elaborou um conjunto de recomendações para a padronização dos laudos mamográficos levando em consideração a evolução diagnóstica e a recomendação da conduta que ficou conhecido

pela sigla BI-RADS® (*Breast Imaging Reporting and Data System*), Tabela 2.2, e recomendada pelo Colégio Brasileiro de Radiologia, Sociedade Brasileira de Mastologia e Federação Brasileira das Sociedades de Ginecologia e Obstetrícia. O objetivo da sistematização é padronizar a nomenclatura dos laudos, que devem possuir conclusão diagnóstica e propor conduta, ressaltando que a mamografia deve sempre ser precedida pelo exame físico e comparada com exames anteriores (Quadros, 2003).

Tabela 2.2 - Categoria BI-RADS® quarta edição (Quadros, 2003).

Categoria	Interpretação	Risco de câncer	Conduta
0	Inconclusivo		Exame adicional (ultra-sonografia, magnificação ou compressão localizada).
1	Benigno	0,05%	Controle anual a partir dos 40 anos
2	Benigno	0,05%	Controle anual a partir dos 40 anos. Como na Categoria 1, esta é uma avaliação “normal”, mas aqui, o mamografista escolhe descrever o achado benigno no laudo mamográfico.
3	Provavelmente benigno	Até 2%	Repetir em seis meses (eventualmente biópsia)
4 (A,B,C)	Suspeito	> 20%	Biópsia 4A (baixa suspeita de malignidade), 4B (intermediária suspeita de malignidade) e 4C (suspeita moderada).
5	Provavelmente maligno	> 75%	Biópsia
6	Lesão já biopsiada e diagnosticada como maligna, mas não retirada ou tratada.	100%	

3 - MÉTODOS DE EXTRAÇÃO DE ATRIBUTOS APLICADOS A IMAGEM MÉDICA

Os atributos, ou características, contidos nas imagens são extraídos geralmente através de técnicas de processamento de imagens. Dificilmente se utiliza apenas uma medida para que se decida a qual classe pertence um caso observado. Isso também ocorre quando se procura classificar automaticamente estruturas detectadas numa imagem médica digital, onde é comum extrair várias medidas de cada padrão e representá-las através de um vetor, que servirá de entrada para um classificador automático.

O desempenho desse classificador, na maioria das vezes Redes Neurais Artificiais (RNA), depende de dois estágios anteriores ao processo de classificação: a aquisição do padrão e a extração e seleção de características que melhor representam cada classe (Duda *et al.*, 1979). É com base nas informações de entrada da rede, que será possível diferenciar as características entre as classes, pois, ruídos poderão prejudicar o desempenho do classificador, fazendo com que aumentem as taxas de erro. Por isso, a análise dos atributos extraídos tem grande importância para a classificação dos padrões.

3.1 - Descritores de Textura

A textura contém informações sobre a distribuição espacial de variações de intensidade dentro de uma faixa de valores, enquanto a intensidade representa o nível de cinza da imagem. Logo, intensidade e textura estão sempre presentes na imagem.

Embora não exista uma definição formal, os descritores de textura fornecem medidas de propriedades como suavidade, rugosidade e regularidade. As três principais abordagens utilizadas em processamento de imagens são (Gonzalez & Woods, 2000):

Abordagem estrutural: visualiza cada textura como sendo repetições de primitivas ou padrões, obedecendo a regras de posicionamento para a sua geração;

Abordagem espectral: baseia-se em propriedades do aspecto de Fourier, sendo utilizada, para a detecção da existência de padrões periódicos ou semi-periódicos através da identificação de picos de alta frequência no espectro;

Abordagem estatística: propicia uma descrição da análise de imagens e extração de características, através de regras estatísticas que coordenam a distribuição e a relação entre seus níveis de cinza. A abordagem mais simples utiliza a distribuição de níveis de cinza em uma imagem ou regiões, sendo utilizado para isso, o histograma. Porém, quando medidas de textura são calculadas apenas a partir do histograma, estas sofrem a limitação de não possuir informações sobre a posição dos *pixels* em relação uns aos outros. Por isso, em abordagens mais “sofisticadas”, devemos considerar não apenas a distribuição de intensidade, mas também as posições dos *pixels*.

Uma ênfase maior será dada a abordagem estatística, sendo este, os descritores de textura de Haralick (Haralick *et al.*, 1979) utilizando-se da matriz co-ocorrência de níveis de cinza (SGLD – *Spatial Grey-Level Dependence*) para calcular a probabilidade de ocorrência combinada de direção e distância entre pares de *pixel* com valores de intensidade semelhantes, separados por uma distância “d”, na orientação “ θ ”. Em outras palavras, $p(i,j)$ indica a frequência de ocorrência de um par de níveis de cinza i e j , medido a partir de uma distância “d” e de um ângulo que pode ser de 0° , 45° , 90° e 135° graus, Figuras 3.1. Na Figura 3.2 é possível verificar que na orientação de 0° a combinação do ton de cinza # (0,0) aparece quatro vezes dentro da imagem e na orientação 90° o mesmo ton de cinza aparece seis vezes dentro da mesma imagem. (Ballard & Brown, 1982; Levine, 1985; Parker, 1997; Sonka *et al.*, 1999).

Figura 3.1 - Esquema demonstrando os ângulos para obtenção da matriz SGLD a partir da imagem.

Figura 3.2 - Cálculo de matrizes de co-ocorrência.

- a) Imagem de 4x4 *pixel* com quatro valores de níveis de cinza (0,1,2,3);
b) Montagem da matriz de co-ocorrência, onde, (i,j) indica o número de *pixels* da imagem com esta combinação de tons de cinza para uma direção e distância;
c) Matriz de co-ocorrência com direção igual a 0° ;
d) Matriz de co-ocorrência com direção igual a 90° ;
e) Matriz de co-ocorrência com direção igual a 135° ;
Matriz de co-ocorrência com direção igual a 45° .

Com base nos cálculos realizados sobre os valores da SGLD, forma-se um conjunto de 14 medidas sendo elas: Energia ou Uniformidade, Contraste, Correlação, Variância, Momento da diferença inversa, Média da Soma, Variância da Soma, Entropia da Soma, Entropia, Variância da Diferença, Entropia da Diferença, Medida de Informação de correlação 1, Medida de Informação de correlação 2 e Máximo Coeficiente de Correlação (Haralick *et al.*, 1973; 1979).

As equações de 1 a 14 dos descritores e seus significados apresentados a seguir, devem considerar n quantidade de níveis de cinza da imagem, $p(i,j)$ a matriz de co-ocorrência dos níveis de cinza e Δx , Δy como sendo a distância de Δx colunas e Δy linhas que separam dois *pixels* vizinhos, sendo eles:

1 - **Uniformidade ou Energia:** indica uniformidade. Texturas homogêneas terão valor de energia mais alto, pois as texturas suaves possuem densidades mais concentradas. Texturas rugosas têm densidades com alta variância.

$$\sum_i \sum_j P(i, j)_{\Delta x, \Delta y}^2 \quad (3.3)$$

2 - **Contraste:** estimativa da variação de intensidade entre pares de pontos da imagem. Para texturas de baixo contraste, essa medida terá um baixo valor e, para texturas de alto contraste, o valor será alto.

$$\sum_i \sum_j (i - j)^2 P(i, j)_{\Delta x, \Delta y} \quad (3.4)$$

3 - **Correlação:** é um indicador de uma estrutura implícita na textura ou um fundo suave.

$$\frac{\sum_i \sum_j ij P(i, j)_{\Delta x, \Delta y} - \mu_l \mu_c}{\sigma_l \sigma_c} \quad (3.5)$$

onde:

$$\mu_l = \sum_i iP(i, *)_{\Delta x, \Delta y}$$

$$\mu_c = \sum_j jP(*, j)_{\Delta x, \Delta y}$$

$$\sigma_l = \sqrt{\sum_i (i - \mu_l)^2 P(i, *)_{\Delta x, \Delta y}}$$

$$\sigma_c = \sqrt{\sum_j (j - \mu_c)^2 P(*, j)_{\Delta x, \Delta y}}$$

$$P(i, *)_{\Delta x, \Delta y} = \sum_j P(i, j)_{\Delta x, \Delta y}$$

$$P(*, j)_{\Delta x, \Delta y} = \sum_i P(i, j)_{\Delta x, \Delta y}$$

4 - **Variância:** indicador da variação da intensidade de fundo da imagem.

$$\sum_i \sum_j \frac{P(i, j)_{\Delta x, \Delta y}}{1 + (i - j)^2} \quad (3.6)$$

5 - **Momento da Diferença Inversa:** medida de homogeneidade local. Enfatiza texturas sutis e pequenas mudanças.

$$\sum_k k P^D(k)_{\Delta x, \Delta y} \quad (3.7)$$

onde:

$$P^D(K) = \sum_{i=1}^{Ng} \sum_{\substack{j=1 \\ |i-j|=k}}^{Ng} p(i, j), \quad k = 0, 1, \dots, Ng - 1.$$

6 - **Média da Soma:** média dos tons do fundo da imagem;

$$\sum_k k P^S(k)_{\Delta x, \Delta y} \quad (3.8)$$

onde:

$$P^S(K) = \sum_{i=1}^{Ng} \sum_{\substack{j=1 \\ i+j=k}}^{Ng} p(i, j), \quad k = 2, 3, \dots, 2Ng$$

7 - **Variância da Soma:** variação dos tons de fundo da imagem;

$$\sum_k (k - MS_{\Delta x, \Delta y})^2 P^S(k)_{\Delta x, \Delta y} \quad (3.9)$$

onde, **MS** é igual a Média da Soma.

8 - **Entropia da Soma:** indica quantidade de informação entre pares de *pixels*;

$$- \sum_k P^S(k)_{\Delta x, \Delta y} \log P^S(k)_{\Delta x, \Delta y} \quad (3.10)$$

9 - **Entropia:** indica quantidade de informação resultante das interações entre os *pixels* da imagem;

$$- \sum_i \sum_j P(i, j)_{\Delta x, \Delta y} \log P(i, j)_{\Delta x, \Delta y} \quad (3.11)$$

10 - **Variância da diferença:** variância calculada com a média centrada em zero;

$$\sum_k (k - MD_{\Delta x, \Delta y})^2 P^D(k)_{\Delta x, \Delta y} \quad (3.12)$$

onde, **MD** é igual a Média da Diferença Inversa.

11 - **Entropia da diferença:** é um indicador de quantidade de desorganização entre os *pixels* de um fundo (semelhante a Soma da Entropia).

$$-\sum_k P^D(k)_{\Delta x, \Delta y} \log P^D(k)_{\Delta x, \Delta y} \quad (3.13)$$

12 - **Medida de Informação de Correlação 1:** é um indicador da correlação baseado na medida da entropia para elementos independentes e pares de elementos na imagem.

$$\sum_k P^D(k)_{\Delta x, \Delta y}^2 \quad (3.14)$$

13 - **Medida de Informação de Correlação 2:** é a media da correlação baseada na similaridade entre entropias de elementos independentes da imagem e pares de elementos da imagem.

$$\sum_k P^S(k)_{\Delta x, \Delta y}^2 \quad (3.15)$$

14 - **Máximo Coeficiente de Correlação:** é um indicador da não homogeneidade da distribuição de níveis de cinza.

$$\sum_i \sum_j \frac{P(i, j)_{\Delta x, \Delta y}^2}{P(i, *)_{\Delta x, \Delta y} P(*, j)_{\Delta x, \Delta y}} \quad (3.16)$$

3.2 - Descritores de Intensidade

A análise de textura de imagens mamográficas propicia vários tipos de análises de lesões, o que auxilia na prática médica. O formato e o contorno são fatores cruciais na análise e caracterização de lesões mamárias (Kopans, 2000), para elaboração do diagnóstico do câncer de mama. Por isso, a preocupação em se tratar desse problema em primeira instância. Porém, além dos descritores geométricos, uma análise de textura pode ser de fundamental importância no momento do diagnóstico de casos mais complexos. Essa preocupação em quantizar a densidade das lesões, ou mesmo da mama, deve-se também à análise prevista na padronização BI-RADS.

Alguns trabalhos para quantificar a variação de densidade óptica em mamogramas foram desenvolvidos por Zheng, et al. (Zheng, 1997). Eles elaboraram uma metodologia para quantificar o grau de dificuldade de identificação de lesões através de medidas que nomearam “índice de dificuldade”. Para isso, foram calculadas medidas para a análise de textura de áreas de interesse contendo nódulos mamários. A primeira etapa desse trabalho foi a definição do “índice de dificuldade”, baseada em características espaciais e de frequência da imagem. A segunda etapa foi dividir o conjunto de imagens em três subconjuntos, de acordo com os “índices de dificuldade” (Zheng, 1997).

Para classificar as imagens pelo grau de dificuldade, as seguintes características foram calculadas a partir do histograma de cada uma:

S_1 : a taxa entre o valor de pico no histograma e a área total de tecidos mais densos (parte mais clara) e menos densos da imagem (parte mais escura);

S_2 : a diferença entre o valor de pico e o valor médio do histograma segmentado;

S_3 : o desvio padrão da distribuição incluída no histograma segmentado;

S_4 : o desvio da distribuição do histograma; e

S_5 : o número de máximo local no histograma.

As seguintes características dependentes de frequência também foram calculadas:

S_6 : a média dos valores de cinco medidas de frequência na porção central da mama com cinco janelas parcialmente sobrepostas, cada janela de 128X128 *pixels*;

S_7 : o intervalo de valores de frequências nas cinco janelas (valores mínimos e máximos);

S_8 : o intervalo do número de *pixels* remanescentes depois de ser submetida a um filtro e à subtração de imagem na etapa de detecção de microcalcificações e *thresholding* para processamento da área total das imagens mamográficas; e

S_9 : o intervalo do número de *pixels* remanescentes depois de ser submetida a um filtro e à subtração de imagem na etapa de detecção de massa e *thresholding* para processamento da área total das imagens mamográficas.

Outros atributos foram calculados com base nos descritores de Haralick. As descrições dos atributos estão listadas a seguir:

1 - *Conspicuidade*: esse atributo correlaciona-se bem com a dificuldade na detecção da massa. Isso é definido como o "contraste da lesão" dividido pela "complexidade de borda". O contraste da lesão é definido pela diferença da média dos valores de *pixels* dentro da lesão e do fundo da imagem; enquanto a complexidade de borda é definida por $\frac{1}{N_M} \sum_{i=1}^{N_T} \left\| \text{Max}(I_i - I_F) \right\|$, N_M e N_T são o número total de *pixels* dentro da região da massa e no fundo, respectivamente. $\text{Max}(I_i - I_F)$ é a diferença máxima entre os valores de *pixels* de fundo e sua vizinhança (para calcular usa-se uma janela de 7×7 *pixels*)

2 - *Circularidade*: calcula-se o tamanho da região da massa (em número de *pixels* N_M), e é calculado o centro da massa (centro de gravidade). Para um círculo para o mesmo tamanho da região de massa, é calculado o número de *pixels* localizados dentro do contorno da massa e o círculo N_C . A *circularidade* é definida por N_C / N_M , a taxa de *pixels* da "massa" convertida para o círculo detectado e o total de *pixels* dentro da região de massa;

3 - *Fator de Gross shape*: esse atributo fornece informação sobre a forma da massa e é definido como: N_b^2 / N_M , onde N_b é o comprimento em *pixels* do perímetro da borda da massa. Grandes valores representam maior complexidade de borda.

4 - *Desvio do comprimento radial normalizado*: o comprimento radial r_k é definido como a distância entre o centro de massa e um ponto k localizado na borda da massa. Essa característica indica mudanças microscópicas no formato da borda da massa. Ela é

calculada por $\sqrt{\frac{1}{N_b} \sum_{k=1}^{N_b} \left(\frac{r_k - m_r}{m_r} \right)^2}$, onde m é a média da distância radial.

5 - *Variação dos valores de pixel*: essa característica mede a suavização global da intensidade dos *pixels* na região da massa e é definida por $\sqrt{\frac{1}{N_M} \sum \left(I_i - \bar{I} \right)^2}$, onde $\bar{I}$ é a média dos *pixels* na região da massa.

As características seguintes são propostas com o objetivo de analisar textura e ainda quantificar a densidade de regiões de interesse contendo lesões mamárias.

6 - *Fração de pixels de mínimo local*: essa característica representa a flutuação local dos *pixels* dentro da região de interesse;

7 - *Profundidade média do mínimo local*: essa característica mede a magnitude da flutuação local do valor de *pixel* dentro da região de interesse;

8 - *Gradiente médio na região de borda*: essa característica mede o contraste da massa na borda.

9 - *Densidade Integrada (DI)*: essa característica é definida multiplicando-se o tamanho da região pela média de contraste, na qual se simula o volume de uma massa.

10 - *Dimensão fractal e outros descritores de Fourier*: essas características são exploradas para caracterização de textura de lesões.

Uma descrição mais detalhada de todos esses 10 atributos pode ser vista em (Zheng, 2001).

Para a extração dos atributos de intensidade, será necessário implementar uma rotina de varredura *pixel a pixel* da imagem. Assim, é possível encontrar os *pixels* de menor e maior intensidade da região. Os *pixels* de menor intensidade geralmente estão associados a tecidos gordurosos (Wang et al., 1999; Patrocínio, 2004), e os *pixels* de maior intensidade a tecidos mais densos (fibroglandulares) ou a lesões.

Os atributos de intensidade que serão extraídos das imagens são (Patrocínio, 2004):

- Média de intensidade do histograma;
- Valor de intensidade do maior pico do histograma;
- Menor intensidade do histograma;
- Maior intensidade do histograma;
- Porcentagem do maior valor de intensidade do histograma em relação à escala de 4096 níveis;
- Diferença da média para o menor valor de intensidade;
- Diferença da média para o maior valor de intensidade;
- Variação de intensidade global da RI (que consiste na média da variação de intensidade de todos os *pixels* da região);
- Índice de variação de intensidade local (DI - Densidade Integrada - que integra as diferenças das variações locais de intensidades e a variação

média, dando uma medida que quantifica contraste entre as partes mais claras da imagem e o restante);

- Quantidade de *pixels* com intensidades maiores que a intensidade do pico do histograma;
- Porcentagem da área da RI com intensidade maior que a intensidade do pico do histograma;
- Quantidade de níveis de cinza da RI.

3.3 - Descritores Geométricos

O formato e o contorno são fatores cruciais na análise e caracterização de lesões mamárias (Kopans, 2000), para elaboração do diagnóstico do câncer de mama. Por isso, a preocupação em se tratar desse problema em primeira instância. Porém, além dos descritores de textura, uma análise geométrica pode ser importante.

3.3.1 - A Teoria dos Momentos

O método dos Momentos proporciona uma técnica robusta para decomposição de uma forma arbitrária em um conjunto de características. O aspecto principal dessa abordagem é que ela se baseia em transformações lineares diretas, sem necessidade de se determinarem parâmetros específicos. Ela apresenta simplicidade matemática e é muito versátil, sendo de uso viável em vários tipos de imagens e aplicações.

Momentos são muito úteis para a análise de forma. Momentos de ordem zero e de primeira, segunda e terceira ordens podem fornecer informações úteis em várias aplicações de visão computacional, como localização dos objetos, reconhecimento de formato, orientação e tamanho, além das características invariantes dos momentos quanto à rotação, translação e escala. A forma é freqüentemente representada por uma imagem binária e seus momentos podem ser obtidos através de algoritmos rápidos (Andersen, 1985).

As técnicas baseadas em momento descrevem as propriedades globais de uma imagem, isto é, a maneira com que as características de *pixels* brancos e pretos representam o padrão.

Em geral, funções de diversas variáveis podem ser caracterizadas por uma seqüência de números, como, por exemplo, coeficientes de Taylor e coeficientes de Fourier. Momentos representam uma técnica descritiva e intuitiva baseada no estudo da Mecânica dos Corpos. Hu, em 1961 (Hu, 1961) desenvolveu a teoria dos Momentos Invariantes (MI) e sugeriu sua aplicação para o reconhecimento invariante de padrões visuais, baseado na teoria dos Invariantes Algébricos (Elliott, 1913). O termo invariante denota uma quantidade (ou um valor) que permanece inalterada sob certas condições. A teoria dos invariantes algébricos de transformação linear, em conexão com uma série de problemas em Geometria Analítica, foi formulada primeiramente no século XIX no trabalho de Carley & Sylvester (Gurevich, 1964). Baseado nesse trabalho, Hu apresentou fórmulas para funções invariantes contendo momentos de segunda e terceira ordens, como exemplos da teoria algébrica de Momentos Invariantes.

Os Momentos Invariantes representam um conjunto completo de descritores de imagem, possuindo, portanto, uma propriedade de fundamental importância para a teoria de Reconhecimento de Padrões (Duda, 1973; Ballard, 1982; Pratt, 1991; Gonzales & Woods, 2000).

As imagens são representadas matematicamente por funções bidimensionais de intensidade de luz $f(x,y)$, onde x e y são as coordenadas espaciais cartesianas e o valor da função f em qualquer ponto (x,y) é proporcional ao brilho da imagem naquele ponto (luminância).

O teorema da Unicidade estabelece que existem momentos de todas as ordens se $f(x,y)$ for contínua e possuir valores não nulos em apenas uma região do plano cartesiano (x,y) (Hu, 1962). O conjunto de momentos $\{m_{p,q}\}$ é determinado de uma maneira única por $f(x,y)$ e $f(x,y)$ é determinada unicamente por $\{m_{p,q}\}$.

Para representar toda a informação em uma região de uma imagem é necessário um número infinito de valores de momentos. Na prática isso é impossível, assim um dos objetivos no projeto de um sistema de reconhecimento que utilize essa técnica é a definição da ordem n dos momentos. Essa ordem deve fornecer informação suficiente para representar a imagem de uma maneira única, respeitando-se os critérios de velocidade de reconhecimento e o poder discriminante dos padrões a serem classificados.

A definição de momentos⁴ (ou algébricos) geométricos regulares tem a forma de uma projeção da função $f(x,y)$, que representa a imagem em uma função monomial $x^p y^q$. O momento $(p+q)$ é definido pela equação (3.20) a seguir:

$$m_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^p y^q \cdot f(x,y) \cdot dx dy \quad (3.17)$$

$$(p, q = 0, 1, 2, \dots)$$

A definição acima tem a forma de uma projeção da função $f(x,y)$ dentro do monômio $x^p y^q$; entretanto, a base, embora completa, não é ortogonal. O cálculo de m_{pq} consiste em se multiplicar a função $f(x,y)$ por um monômio $x^p y^q$ e integrar o resultado.

3.3.1.1 - Os Momentos Invariantes de Hu

O conjunto dos momentos invariantes absolutos consiste em combinações não lineares aplicadas aos momentos, gerando funções invariantes à transformação de rotação. Através dos momentos de segunda e terceira ordem, Hu definiu sete funções denominadas Invariantes de Momento de Hu (MI) (Hu, 1962), que são invariantes à translação, rotação e escala. Essas funções são mostradas pelas Equações 3.18 a 3.24 a seguir.

$$\phi_1 = \mu_{20} + \mu_{02} \quad (3.18)$$

$$\phi_2 = (\mu_{20} - \mu_{02})^2 + 4\mu_{11}^2 \quad (3.19)$$

$$\phi_3 = (\mu_{30} - 3\mu_{12})^2 + (3\mu_{21} - \mu_{03})^2 \quad (3.20)$$

$$\phi_4 = (\mu_{30} + \mu_{12})^2 + (\mu_{21} - \mu_{03})^2 \quad (3.21)$$

⁴Um momento é uma soma ponderada de um padrão $f(x)$ sobre todo o campo de entrada, com os pesos iguais a algum polinômio em x (Gonzales & Wood, 2000).

$$\begin{aligned}\phi_5 = & (\mu_{30} - 3\mu_{12})(\mu_{30} + \mu_{12}) \cdot [(\mu_{30} + \mu_{12})^2 - 3(\mu_{21} + \mu_{03})^2] + \\ & + (3\mu_{21} - \mu_{03})(\mu_{21} + \mu_{03}) \cdot [3(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2]\end{aligned}\quad (3.22)$$

$$\phi_6 = (\mu_{20} - \mu_{02})[(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2] + 4\mu_{11}(\mu_{30} + \mu_{12})(\mu_{03} + \mu_{21}) \quad (3.23)$$

$$\begin{aligned}\phi_7 = & (3\mu_{21} - \mu_{03})(\mu_{30} + \mu_{12})[(\mu_{30} + \mu_{12})^2 - 3(\mu_{21} + \mu_{03})^2] - \\ & - (\mu_{30} - 3\mu_{12})(\mu_{21} + \mu_{03})[3(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2]\end{aligned}\quad (3.24)$$

Os seis primeiros momentos ϕ_1 a ϕ_6 são invariantes à rotação e a reflexão, entretanto ϕ_7 é sensível à reflexão. Seu valor muda de sinal para a imagem refletida de um objeto, mas sua magnitude permanece inalterada. Portanto, caso deseje-se invariância à reflexão apenas os seis primeiros invariantes de Hu devem ser usados, caso contrário, seu sinal deve ser levado em consideração. O sétimo invariante é útil para distinguir imagens refletidas.

Uma outra metodologia para normalização em relação à rotação consiste em rotacionar o objeto para uma posição padrão, método que foi definido por Hu (Hu, 1962) como Momentos Invariantes (MI). Nesse método, os momentos são calculados em referência a um par de eixos principais. A maneira mais fácil de se definir uma posição padrão para o objeto é achar seu eixo principal, ou seja, a direção onde ocorre o maior espalhamento, e rotacioná-lo até que fique horizontal. Fazendo com que a parte mais pesada da figura fique no lado esquerdo. Na linguagem estatística dizemos que o objeto está inclinado à direita. Como exemplo, a Figura 3.3, extraída de (Masters, 1994) mostra a posição padrão.

Figura 3.3 - Posição padrão para Invariância à Rotação (Masters, 1994).

Vários atributos de formato podem ser extraídos dos Momentos Cartesianos. O momento de ordem zero (m_{00}) fornece uma medida de área do objeto. Os momentos de primeira ordem m_{10} e m_{01} (denominados “momentos de alavanca”) calcula-se o centro de massa do objeto, que é utilizado como uma localização padrão do objeto dentro do campo visual e também podem ser usados para calcular o ângulo T do eixo de mínima inércia ou eixo principal da imagem, como mostra a equação 3.14 (Strachan, 1990):

$$T = \frac{1}{2} \arctan \frac{2(m_{00}m_{11} - m_{10}m_{01})}{(m_{00}m_{20} - m_{10}^2) - (m_{00}m_{02} - m_{01}^2)} \quad (3.25)$$

Os momentos de segunda ordem m_{20} , m_{02} (denominados “momentos de inércia”) e m_{11} (denominado produto de inércia), determinam várias características, tais como os eixos principais sobre os quais os segundos momentos são mínimo e máximo (eixo maior e eixo menor respectivamente), a elongação e orientação do eixo principal do objeto. As interpretações dos vários momentos de baixa ordem estão sendo descritos na Tabela 3.1. Essa interpretação possuem uma analogia com a mecânica dos corpos e foram descritas em (Giuliano, 1961).

Tabela 3.1 - Interpretação geométrica dos Momentos Centrais de segunda e terceira ordem.

Momentos Centrais	Interpretação Geométrica	Descrição
μ_{20}	Centralidade horizontal	É determinada pela variância da massa na direção x. Em uma imagem do objeto ela mede a variância da forma do objeto na direção x.
μ_{02}	Centralidade vertical	É determinada pela variância da massa na direção y. Em uma imagem do objeto ela mede a variância da forma do objeto na direção y.
μ_{11}	Diagonalidade	É a distribuição da massa sobre os quatro quadrantes. Ela mede a proporcionalidade da distribuição da forma do objeto entre os 1º e 3º e os 2º e 4º quadrantes, vista do centro de massa, ou seja: - $\mu_{11} < 0$, há mais massa nos 2º e 4º quadrantes; - $\mu_{11} > 0$, há mais massa nos 1º e 3º quadrantes; - $\mu_{11} = 0$, há uma distribuição de massa igual nos 1º e 3º em relação ao 2º e 4º quadrantes.
μ_{12}	Divergência horizontal	Mede a dimensão da figura à esquerda comparada com a sua direita, ou seja, a simetria do objeto na direção x: - $\mu_{12} < 0$, há mais massa nos 2º e 3º quadrantes; - $\mu_{12} > 0$, há mais massa nos 1º e 4º quadrantes; - $\mu_{12} = 0$, há uma distribuição de massa igual nos 2º e 3º em relação ao 1º e 4º quadrantes.
μ_{21}	Divergência vertical	Mede a dimensão da parte inferior da figura comparada com a sua parte superior, ou seja, a simetria do objeto na direção y: - $\mu_{21} < 0$, há mais massa nos 3º e 4º quadrantes; - $\mu_{21} > 0$, há mais massa nos 1º e 2º quadrantes; - $\mu_{21} = 0$, há uma distribuição de massa igual nos 3º e 4º em relação ao 1º e 2º quadrantes.
μ_{30}	Desequilíbrio horizontal	Determina a localização do centro de gravidade (CG) com relação à metade da largura ($X_{l/2}$) do objeto, ou seja: - $\mu_{30} < 0$, CG ficará à direita de $X_{l/2}$; - $\mu_{30} > 0$, CG ficará à esquerda de $X_{l/2}$; - $\mu_{30} = 0$, $\bar{x} = X_{l/2}$.
μ_{03}	Desequilíbrio vertical	Determina a localização do centro de gravidade (CG) com relação a metade da altura ($Y_{h/2}$) do objeto. - $\mu_{03} < 0$, CG ficará acima de $Y_{h/2}$; - $\mu_{03} > 0$, CG ficará abaixo de $Y_{h/2}$; - $\mu_{03} = 0$, $\bar{y} = Y_{h/2}$.

Outra propriedade que pode ser determinada pelos momentos de segunda ordem é o Raio de Giração (RG) da imagem, que pode ser interpretado também como o raio mínimo que inclui a maioria, senão todos os pontos em seu interior. O Raio de Giração sobre um eixo é à distância do eixo à linha onde toda massa está concentrada, sem alterar o segundo momento sobre o eixo. Os Raios de Giração sobre os eixos x e y são

dados pelas Equações 3.26 e 3.27, e medem respectivamente, o desvio padrão σ_x e σ_y do objeto nas direções x e y.

$$RG_x = \sigma_x = \sqrt{\frac{\mu_{20}}{m_{00}}} \quad (3.26)$$

$$RG_y = \sigma_y = \sqrt{\frac{\mu_{02}}{m_{00}}} \quad (3.27)$$

O Raio de Giração sobre a origem é o raio de um círculo centrado na origem onde toda massa está centrada, sem alterar o segundo momento sobre a origem, e é dado pela Equação 3.28.

$$RG_{xy} = \sqrt{\frac{\mu_{20} + \mu_{02}}{\mu_{00}}} \quad (3.28)$$

O Raio de Giração em relação à origem é inerentemente invariante à orientação da imagem e conseqüentemente tem sido utilizado como característica invariante à rotação para representação de objetos.

3.3.2 - Outros Atributos de Forma

O perímetro, a área e, medidas derivadas desses dois atributos, são características extraídas de uma cena ou objeto que muito podem contribuir para separação das classes. Essas características são utilizadas em vários esquemas CAD, pois, em achados mamográficos, por exemplo, o formato, tamanho e distribuição dos objetos, são importantíssimos na análise da imagem e laudo médico. A seguir estão apresentados alguns desses atributos que também podem ser extraídos de imagens médicas:

- 1 - **Área:** é dada pelo número total de *pixels* do objeto;
- 2 - **Perímetro:** é dado pelo número de *pixels* do contorno do objeto;
- 3 - **Compacidade:** é uma medida derivada do perímetro P e área A de um objeto, conforme Equação 3.29.

$$C = P/4\pi A. \quad (3.29)$$

4 - **Irregularidade:** Tao (Tao, 1998), utilizou a Equação 3.30 para extrair irregularidade de fronteira, como sugestivo de malignidade.

$$I = A/P^2 \quad (3.30)$$

Muitas outras medidas de formato podem ser usadas nos esquemas CAD, para extrair informações de microcalcificações, regiões de interesse e nódulos. Essas medidas, quando combinadas, representam bem as classes em que se dividem os achados mamográficos.

3.4 - Conclusão

O processamento de imagem para a extração de atributos e para a identificação de estruturas dentro das imagens envolve o conhecimento da sua amplitude e distribuição espacial. É através do processamento de imagens que as informações necessárias para o reconhecimento de padrões serão extraídas.

Porém, a extração de informações da imagem depende do tipo de problema que se deseja resolver, ou seja, os vários tipos de atributos devem ser relacionados diretamente ao problema. Muitos desses atributos extraídos das imagens podem conter informações redundantes que influenciam a etapa de classificação. Por isso, a seleção prévia das melhores informações que irão caracterizar o problema, e que servirão de entrada para o classificador, são muito importantes para se obter uma eficiente classificação.

4 - A INTELIGÊNCIA ARTIFICIAL E AS REDES NEURAIS ARTIFICIAIS

O “sonho” de construir máquinas inteligentes vem desde a antigüidade, quando o homem procurou desenvolver dispositivos artificiais metálicos, de madeira ou de marfim, dotados de movimento e inteligência (Tafner *et al.*, 1996).

O termo Inteligência Artificial (IA) foi proposto em 1956, por John MacCarthy (Maccarthy, 1963) da Universidade de Stanford, sendo este um dos pioneiros em seu estudo.

A IA pode ser encontrada na seqüência de Abordagem Simbólica até a Conexionista. A **abordagem simbólica ou programada** é fortemente influenciada pelos estudos em psicologia, dando ênfase aos processos cognitivos, ou seja, a forma como o ser humano raciocina. Essa abordagem tem como objetivo estudar o comportamento inteligente baseado em aspectos psicológicos e processo algorítmico, representando o conhecimento por sentenças declarativas e de raciocínio lógico (Minsky & Papert, 1969). Já a **abordagem conexionista ou neoconexionista** também conhecida como abordagem biológica, tem como base os estudos da neurofisiologia, ou seja, estrutura funcional do cérebro, dos neurônios e das conexões neurais, chamadas de sinapses (Mcculloch & Pitts, 1943; Hebb, 1949; Rosenblatt, 1958; Widrow & Hoff, 1960). Como este estudo é direcionado às Redes Neurais Artificiais (RNA), será dada maior ênfase à abordagem conexionista.

4.1 - Redes Neurais Artificiais

As RNAs são biologicamente inspiradas na anatomia do cérebro humano, ou seja, são compostas por elementos que imitam as mais elementares funções de um neurônio biológico e dos sistemas nervosos. Como exemplo de propriedades típicas do cérebro, as RNA aprendem a partir da experiência e generalizam novos exemplos a partir de exemplos prévios, abstraindo características essenciais de entrada, mesmo contendo dados irrelevantes (Haykin, 1994; Azevedo *et al.*, 2000).

Para que uma RNA possa simular o funcionamento de uma Rede Neural Natural (RNN), ela utiliza o processamento paralelo distribuído⁵, composto por unidades de processamento simples, chamadas de nodos. O modelo matemático simula o paralelismo da rede neural através de um algoritmo (Braga *et al.*, 2000).

O primeiro modelo de neurônio artificial foi proposto em 1943, pelo fisiologista McCulloch e pelo matemático Walter Pitts da Universidade de Illinois, cujo estudo baseava-se no fato de que, em um dado instante de tempo, o neurônio ou está disparando pulsos elétricos ou está inativo, correspondendo assim, ao “verdadeiro e falso” do cálculo lógico, ou ao “zero e um” da álgebra booleana, conforme demonstrado na Figura 4.1 (Haykin, 1994; Azevedo *et al.*, 2000; Braga *et al.*, 2000).

Figura 4.1 - Neurônio de McCulloch e Pitts.

As RNAs foram propostas para resolver problemas em que os seres humanos possuem boa performance, porém são de difícil tratamento pelos computadores

⁵Processamento paralelo distribuído: quando se utiliza mais de um processador assumindo que os processadores não compartilham a memória, ou seja, cada processador tem a sua memória (Almasi & Gottlieb, 1994; Quinn, 1994; Tanenbaum & Steen, 2002).

tradicionais como, por exemplo, no reconhecimento de imagens (Marar & Carvalho Filho, 1994).

O neurônio artificial é a unidade computacional básica que forma a rede neural artificial, e pode ser chamado de unidade de processamento, nó, nodo ou processador. Sua estrutura, Figura 4.2, é composta de uma ou mais entradas ($x1, x2, \dots, xn$), onde, para cada entrada haverá um peso ($w1, w2, \dots, wn$) que será multiplicado e a soma (Σ) desses resultados levará à excitação do neurônio, recebendo o nome de entrada ponderada. Depois de acumulado o valor somado, será comparado com um limiar (Fa), ou seja, um valor estipulado, que depois de atingido será transferido (Ft) através da saída e que poderá afetar a resposta final da rede, ou os neurônios da próxima camada (Haykin, 1994; Braga *et al.*, 2000).

Figura 4.2 - Neurônio artificial completo, onde, X_i = Entrada; W_i = Pesos;
 $\Sigma = X_i * W_i$; Fa = Limiar e Ft = Função de transferência.

Os pesos, representam o grau de importância que determinada entrada possui em relação àquele determinado neurônio, ou seja, o sinal que passa pela sinapse depende da intensidade do sinal de entrada e do peso correspondente. Quando uma entrada é bastante estimulada, acaba estimulando também, os pesos correspondentes à sua conexão que irão influenciar o resultado do sinal de saída. A função de ativação repassa o sinal para a saída do neurônio, sendo esta, uma função de ordem interna, cuja atribuição é fazer acontecer um nível de ativação dentro do próprio neurônio. A decisão é tomada pelo neurônio sobre o que fazer com o valor resultante do somatório das entradas ponderadas. Já a função de transferência, também conhecida como limiar lógico (*threshold*), define e envia para fora do neurônio o valor passado pela função de ativação.

As funções de transferências mais conhecidas são:

1 - As **funções rampa e limite**: que possuem decisões rípidas, principalmente para valores extremos, refletindo a saída dentro de uma faixa, como exemplo entre 0 e 1. Isto quer dizer que, ultrapassando um certo limite, a função dispara o valor 0, ou 1, ou -1,

dependendo da função e da forma que será utilizada, como podem ser visualizados na Figura 4.3 (Hertz, 1991; Haykin, 1994; Azevedo *et al.*, 2000; Braga *et al.*, 2000).

Figura 4.3 - Funções rampa e limite. a) Limite ríspido; b) Função rampa.

2 - A **função sigmóide**: função de ativação mais utilizada na construção de redes neurais artificiais, sendo uma função estritamente crescente, que exibe um balanceamento adequado entre comportamento linear e não-linear. Um exemplo de função sigmóide é a função logística. Quando o parâmetro de inclinação se aproxima do infinito, a função sigmóide se torna simplesmente uma função limiar. Enquanto a função limiar assume o valor de 0 ou 1, uma função sigmóide assume um intervalo contínuo de valores entre 0 e 1, conforme demonstrado na Figura 4.4 (Hertz, 1991; Haykin, 1994; Azevedo *et al.*, 2000; Braga *et al.*, 2000).

Figura 4.4 - Função sigmóide.

4.1.1 - Arquiteturas de Redes Neurais Artificiais

A arquitetura de uma RNA define a forma como seus neurônios estão organizados, podendo ser diferenciadas umas das outras em função do número de camadas e dos arranjos das conexões. Conforme pode ser visualizado na Figura 4.5, genericamente as RNA possuem: **camada de entrada**, que é utilizada para captar estímulos externos e repassá-los para a camada intermediária; **camadas intermediárias ou escondidas**, cujas saídas dos neurônios não são acessadas por procedimentos externos à RNA; e a **camada de saída**, que retrata o resultado produzido pela RNA em resposta a uma dada entrada (Haykin, 1994; Azevedo *et al.*, 2000; Braga *et al.*, 2000).

Figura 4.5 - Camadas de uma RNA genérica ou Rede Multicamadas.

Em relação ao tipo de conexões, as RNAs podem ser classificadas em: (a) *feedforward* e (b) *feedback*.

a) As ***Feedforward*** são redes de fluxo direto, onde todos os pontos de conexão seguem em uma direção, propagando-se para frente. Todos os nós estão conectados entre si, ou seja, os neurônios de uma dada camada estão conectados com todos os neurônios da camada anterior, conforme a Figura 4.6 (Hertz, 1991; Zurada, 1992; Haykin, 1994; Azevedo *et al.*, 2000; Braga *et al.*, 2000).

Figura 4.6 - Rede *Feedforward*.

b) A **rede *Feedback*** (realimentação), por outro lado, é aquela em que o sinal de saída de um neurônio serve como entrada para a mesma camada, uma camada anterior, entre camadas alternadas ou para partes específicas de uma camada qualquer. O sinal pode ser usado tanto para excitar a camada inteira como também para excitar apenas um neurônio em particular, ou até mesmo o próprio neurônio que realizou o disparo, conforme a Figura 4.7 (Hertz, 1991; Zurada, 1992; Haykin, 1994; Azevedo *et al.*, 2000; Braga *et al.*, 2000).

Figura 4.7 - Rede *FeedBack*. a) Conexão entre camadas alternadas; b) A saída de um neurônio serve como entrada para a mesma camada.

4.1.2 - Aprendizagem

A característica mais interessante e a mais importante das RNAs é a sua habilidade de “aprender” a partir do seu ambiente e melhorar seu desempenho ao longo do tempo, através de ajustes aplicados aos pesos sinápticos e *thresholds* (Haykin, 1994).

Se uma rede “aprende”, ela, obviamente, retém conhecimento; porém, esse conhecimento não está localizado em um endereço e, dessa forma, a rede não separa memória de dados armazenados, ou seja, o conhecimento armazenado está distribuído por toda a rede. Da mesma forma que não se pode analisar minuciosamente um cérebro para

extrair conhecimento, projetistas de redes neurais não podem simplesmente olhar os neurônios e dizer onde a informação está armazenada (Tafner *et al.*, 1996).

O aprendizado nas RNA acontece basicamente de duas formas. No **aprendizado supervisionado**, em que, o conhecimento é adquirido através dos chamados “professores”, ou seja, pares de entrada são apresentados à rede para ser verificado se a saída obtida, gerada a partir dos cálculos efetuados com os pesos que a rede possui, foi a desejada. Porém, se a saída da rede for diferente da desejada, a rede irá calcular um erro que estará representando a distância da resposta desejada. Com isso, a rede irá ajustar os pesos até que o erro seja mínimo e esteja dentro de uma faixa considerada satisfatória. Já o **aprendizado não-supervisionado** não necessita da figura do “professor”, pois não requer uma saída específica desejada. São usados apenas os valores de entrada, para o treinamento da rede, que utiliza os neurônios como classificadores, e os dados de entrada como os elementos para classificação. A auto-organização envolve os processos de competição e de cooperação entre os neurônios da rede. Muitos pesquisadores têm utilizado esse tipo de rede como detector de características, dada a sua capacidade de aprender a diferenciar estímulo ocorrido em partes espacialmente diferentes (Hertz, 1991; Haykin, 1994; Azevedo *et al.*, 2000; Braga *et al.*, 2000).

4.2 - Rede *Multi-Layer Perceptron*

A Rede *Multi-Layer Perceptron* (MLP) proposta por Rumelhart *et al.* (Rumelhart *et al.*, 1986) é também conhecida com Rede *Backpropagation* e muito utilizada como classificador em esquemas CAD (Patrocínio *et al.*, 2000; Patrocínio *et al.*, 2001a; Patrocínio *et al.*, 2001b; Bilska-Wolak *et al.*, 2005). O algoritmo *backpropagation*, que é supervisionado, tem o objetivo de calcular o erro para a camada de saída e propagar este no sentido saída-entrada, ajustando os pesos de todas as camadas, através da retropropagação do erro (Haykin, 1994).

O treinamento possui duas fases: a fase *forward*, utilizado para definir a saída da rede para um dado padrão de entrada, e a fase *backward*, que utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões (Hertz *et al.*, 1991; Haykin, 1994; Azevedo *et al.*, 2000; Braga *et al.*, 2000). A rede MLP só será considerada treinada quando o erro entre as saídas obtidas e as saídas desejadas estiver reduzido a um

valor aceitável, ou seja, um valor baixo que irá depender da aplicação para qual a rede está sendo treinada.

A rede MLP é uma rede multicamadas, onde o processamento de cada nódulo é combinado com o processamento realizado pelos outros nódulos da camada anterior que estão conectados a ele. A arquitetura pode ser diferenciada em função do número de camadas e dos arranjos das conexões.

Segundo Haykin (Haykin, 1994), o algoritmo resumido segue os seguintes passos:

1 - **Inicialização:** o vetor peso $\mathbf{w}_j(\mathbf{0})$ deve ser inicializado com valores aleatórios, normalmente entre -1 e 1.

2 - **Apresentação dos Exemplos de Treinamento:** retira-se uma amostra do vetor $\mathbf{x}$, ou seja, apresenta-se um vetor de exemplos de treinamento à rede. Para cada exemplo do conjunto, realizam-se as seqüências para frente e para trás descritas nos pontos 3 e 4.

3 - **Propagação:** supondo que um exemplo de treinamento da época seja representado por $(\mathbf{x}(n), \mathbf{d}(n))$, com o vetor de entrada $\mathbf{x}(n)$ aplicado à camada de entrada de nós sensoriais e o vetor resposta desejada $\mathbf{d}(n)$ apresentado à camada de saída de nós computacionais, os campos locais induzidos são calculados e os sinais funcionais da rede prosseguem para frente, camada por camada. O campo local induzido $v_j^{(l)}(n)$ para o neurônio j na camada l é calculado através da Equação 4.1

$$v_j^{(l)}(n) = \sum_{i=0}^{m_0} w_{ji}^{(l)}(n) y_i^{(l-1)}(n) \quad (4.1)$$

onde $y_i^{(l-1)}(n)$ é o sinal (função) de saída do neurônio i na camada anterior $l-1$, na iteração n , e $w_{ji}^{(l)}(n)$ é o peso sináptico do neurônio j da camada l , que é alimentado pelo neurônio i da camada $l-1$. Para $i=0$, temos $y_0^{(l-1)}(n) = +1$ e $w_{j0}^{(l)}(n) = b_j^{(l)}(n)$ é o *bias*, que tem efeito de aumentar ou diminuir a entrada líquida da função de ativação dependendo se ele é positivo ou negativo, aplicado ao neurônio j na camada l . Assumindo-se o uso de uma função sigmóide, o sinal de saída do neurônio j na camada l é dada pela Equação 4.2

$$y_j^{(l)} = \varphi_j(v_j^{(l)}(n)) \quad (4.2)$$

onde, $\varphi(\cdot)$ é função de ativação associada ao neurônio. Se o neurônio j está na primeira camada oculta (i.e., $l=1$), deve-se seguir a Equação 4.3.

$$y_j^{(0)}(n) = x_j(n) \quad (4.3)$$

onde $x_j(n)$ é o j -ésimo elemento do vetor de entrada $x(n)$. Se o neurônio j está na camada de saída (i.e., $l=L$, onde L é denominado a profundidade da rede), conforme Equação 4.4.

$$y_j^{(L)} = o_j(n) \quad (4.4)$$

onde, $o_j(n)$ é o j -ésimo elemento do vetor (padrão) de saída. O sinal de erro será calculado pela Equação 4.5.

$$e_j(n) = d_j(n) - o_j(n) \quad (4.5)$$

onde $d_j(n)$ é o j -ésimo elemento do vetor resposta desejada $d(n)$.

4 - **Retropropagação:** os gradientes locais (δ s) da rede, definidos pela Equação 4.6.

$$\delta_j^{(l)}(n) = \begin{cases} e_j^{(L)}(n) \varphi_j'(v_j^{(L)}(n)) & \text{para o neurônio } j \text{ da camada de saída } L \\ \varphi_j'(v_j^{(l)}(n))' \sum_k \delta_k^{(l-1)}(n) w_{kj}^{(l+1)}(n) & \text{para o neurônio } j \text{ na camada oculta } l \end{cases} \quad (4.6)$$

onde o apóstrofe em $\varphi_j'(\cdot)$ representa a diferenciação em relação ao argumento. Ajuste os pesos sinápticos da rede na camada l de acordo com a regra delta generalizada seguindo a Equação 4.7.

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha [w_{ji}^{(l)}(n-1)] + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad (4.7)$$

onde η é o parâmetro da taxa de aprendizagem e α é a constante de momento.

5 - **Continuação:** os passos 3 e 4, devem ser repetidos apresentando novos vetores de exemplos de treinamento para a rede, até que seja satisfeito o critério de parada.

4.3 - Rede *Self-Organizing Map*

Também conhecida como mapa de Kohonen, *Self-Organizing Map* (SOM) ou Mapa auto-organizável, foi desenvolvida em 1984, por Teuvo Kohonen (Kohonen, 1984). Essa rede neural de treinamento não supervisionado do tipo *feedforward*, não possui uma forma topológica padrão podendo ser hexagonal, retangular, triangular, etc. (Haykin, 1994; Azevedo *et al.*, 2000).

A Rede de Kohonen possui topologia básica de duas camadas, sendo elas: camada de entrada $1 \times N$, responsável por ler o vetor de entrada e apresentar à rede as informações que serão classificadas; e a camada de saída $N \times N$, que forma uma resposta que pode ser uni ou bidimensional, Figura 4.8.

Figura 4.8 - Mapa de Kohonen.

Essa RNA tem a propriedade de se modificar, sendo auto-organizável, de modo que, o processo de vizinhança é uma competição pelo melhor aprendizado, ou seja, quem aprender melhor será o vencedor ou o neurônio cujo vetor de pesos gerar a menor distância Euclidiana⁶ com o vetor de entrada será o vencedor. O ajuste da vizinhança é uma espécie de estímulo aos neurônios que ficam em torno do vencedor para que possam vir a ter as mesmas condições de disputa com o neurônio vencedor, e dessa forma, responder também ao fato apresentado à rede (Hertz *et al.*, 1991; Haykin, 1994; Azevedo *et al.*, 2000; Braga *et al.*, 2000).

A aplicação do algoritmo é composta por três passos principais: amostragem, seleção do neurônio vencedor e atualização, sendo repetidos até que o mapa de

características esteja completo (Haykin, 1994). O algoritmo resumido segue os seguintes passos:

- 1 - **Inicialização:** o vetor peso $\mathbf{w}_j(0)$ deve ser inicializado com valores aleatórios sendo diferentes para $j = 1, 2, \dots, l$, onde l é o número de neurônios da grade.
- 2 - **Amostragem:** retira-se uma amostra do vetor $\mathbf{x}$ que possui dimensão igual a m e representa o padrão de ativação que é apresentado a grade.
- 3 - **Seleção do neurônio vencedor:** utilizando o critério de mínima distância euclidiana, deve-se encontrar o neurônio vencedor $i(\mathbf{x})$ no passo de tempo n , conforme a Equação 4.8.

$$i(x) = \arg \min_j \|x(n) - w_j\|, j = 1, 2, \dots, l \quad (4.8)$$

- 4 - **Atualização:** através da fórmula de atualização, Equação 4.9, os vetores de peso sinápticos de todos os neurônios devem ser ajustados.

$$\sigma(n) = \sigma_0 \exp\left(-\frac{n}{\tau_1}\right) n = 0, 1, 2, \dots, \quad (4.9)$$

onde, σ é a largura da função de vizinhança topológica, σ_0 é o valor inicial de σ , n será o tempo discreto e τ_1 é uma constante de tempo. O cálculo da distância entre o neurônio vencedor e o excitado é dado pela Equação 4.10.

$$d_{j,i}^2 = \|r_j - r_i\|^2 \quad (4.10)$$

onde, $d_{j,i}$ é a distância lateral entre o neurônio vencedor $i(x)$ e o neurônio excitado j , r_j define a posição do neurônio excitado j e r_i define a posição do neurônio vencedor $i(x)$. A função de vizinhança será calculada conforme a Equação 4.11.

$$h_{j,i(x)}(n) = \exp\left(-\frac{d_{j,i}^2}{2\sigma^2(n)}\right), n = 0, 1, 2, \dots, \quad (4.11)$$

⁶Distância Euclidiana, seja E um espaço euclidiano. Dados os vetores $\mathbf{x}$ e $\mathbf{y} \in E$, definimos **distância** entre $\mathbf{x}$ e $\mathbf{y}$, o comprimento do vetor $\mathbf{x} - \mathbf{y}$, isto é:
 $d(x, y) = \|\mathbf{x} - \mathbf{y}\| \rightarrow d(x, y) = \sqrt{(x - y, x - y)}$.

onde, $h_{j,i(x)}$ é a função de vizinhança centrada em torno do neurônio vencedor $i(x)$. Para a atualização dos pesos, deve ser seguida a Equação 4.12.

$$w_j(n+1) = w_j(n) + \eta(n)h_{j,i(x)}(n)(x(n) - w_j(n)) \quad (4.12)$$

onde, $\eta(n)$ é o parâmetro da taxa de aprendizagem.

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

A grande importância dos Mapas Auto-Organizáveis está na capacidade de extrair as características comuns dos padrões de entradas definidos num espaço n -dimensional para uma representação normalmente bidimensional, onde é possível visualizar agrupamentos de padrões com características semelhantes. Por isso, essa rede deve ser aplicada em casos, nos quais, exista um conjunto de dados e necessite fazer a separação dessas informações em padrões com características em comum.

Um exemplo que pode ser citado é o trabalho realizado por Markey *et al.* (Markey *et al.*, 2003), que possui um banco de dados com 2258 casos heterogêneos baseados em resultados das mamografias e idade da paciente e ele necessita separar essas imagens para identificar subtipos clínicos como distorções arquitetônicas, massas, e calcificações.

4.4 - Conclusão

A classificação tem como objetivo principal associar um conjunto de informações pré-definidas com base em atributos e características, que identifique a melhor classe que irá caracterizar o caso em estudo.

A tarefa de classificação ocorre em várias áreas da atividade humana e as pesquisas na área têm sido bastante direcionadas à construção de procedimentos automáticos de classificação. Além dos estudos envolvendo a classificação, outras técnicas vêm sendo estudadas para melhorar a separação de classes, reconhecimento de padrões e tomada de decisões.

5 - CLASSIFICADORES AUTOMÁTICOS EM ESQUEMAS CADs

Neste capítulo são expostos conceitos sobre vários classificadores para esquemas CAD. A revisão literária permite verificar que diversos trabalhos utilizando técnicas de Processamento de Imagens, Reconhecimento de Padrões, Visão Computacional e Inteligência Artificial vêm sendo desenvolvidos, como parte de esquemas CAD, buscando auxiliar radiologistas na detecção e classificação de lesões.

O objetivo do estudo realizado por Mudigonda *et al.* (Mudigonda *et al.*, 2000) foi a classificação de massas benignas e malignas de mamogramas, calculando atributos baseados em gradiente e texturas. Além de mudanças de textura causadas por microcalcificações, a presença de massas espiculares causa perturbações na homogeneidade de tecidos, e pode resultar em distorção arquitetônica no parênquima da mama. Como resultado, muitos estudos focalizaram a quantificação do conteúdo de textura nas regiões de interesse (RIs) e margens das massas.

Eles propuseram calcular o gradiente e textura baseadas em matrizes de co-ocorrência de nível cinza (SGLD – *Spatial Grey-Level Dependence*) para avaliar a informação de textura por regiões do centro da massa comparada com as informações de texturas presentes nas margens da massa. Para calcular as medidas baseadas no gradiente é necessário extrair a intensidade dos *pixels* de dentro do limite de massa para o exterior ao longo da direção perpendicular em todos os pontos da borda. Os *pixels* extraídos formam uma tira ou faixa de *pixels* que eles propuseram analisar usando atributos de textura baseado em matriz de co-ocorrência de níveis de cinza.

Foi calculado cada vetor normal e traçado nas quatro direções (0°, 45°, 90°, e 135°) isso está disponível como linhas diretas em uma grade discreta. A Figura 5.1 mostra um mamograma de 900x1000 *pixels* que contém uma massa benigna circunscrita.

Figura 5.1 - Mamograma de 900x1000 *pixels* que contém uma massa benigna circunscrita (Mudigonda *et al.*, 2000).

Figura 5.2 - Extração da normal, mostrado em linhas pretas a borda da massa benigna da Figura 5.1.

Figura 5.3 - Tira ou faixa de *pixels* extraída pelo limite de massa benigna da Figura 5.1 é extraído pelo cálculo do gradiente e de características de textura.

As Figuras 5.2 e 5.3 mostram a normal e a tira de largura máxima de 8 mm pelo limite (4 mm ou 80 *pixels* em qualquer lateral do limite onde disponível, a uma resolução de 50 μm por *pixel*). Uma imagen semelhante para um tumor espicular maligno (tamanho de cada imagem 560 x 630 *pixels*) é apresentado na Figura 5.4.

Figura 5.4 - Mamograma de 560x630 *pixels* que contém uma massa maligna espicular (Mudigonda *et al.*, 2000).

Figura 5.5 - Extração da normal mostrado em linhas pretas a borda da massa maligna espicular da Figura 5.4.

Figura 5.6 - Tira ou faixa de *pixels* extraída pelo limite de massa maligna da Figura 5.4 é extraída pelo cálculo do gradiente e de características de textura.

Como pode ser visto nas Figuras 5.5 e 5.6, o método proposto pode se adaptar à complexidade das formas de um nódulo. A largura das tiras é limitada a um máximo de 80 *pixels* em qualquer lado ou profundidade da massa. Isto especialmente é significativo no

caso de nódulos espiculares possuindo finas espículas ou microlobulares, tal que a normal não achesse em espículas adjacentes ou porções de massa. Em três das 54 imagens analisadas neste trabalho, as massas ficaram situadas perto das extremidades das imagens. Nestes casos, foi limitada a largura da tira, *pixel a pixel*, em 4 mm sendo esta determinada pelo radiologista especializado em mamografia para levar em conta a possível profundidade de infiltração ou difusão de massas nos tecidos circunvizinhos.

Um total de 54 imagens foram testadas sendo 28 benignas e 26 malignas, contendo 39 imagens da *Mammographic Image Analysis Society* (MIAS) e 15 imagens de um banco de dados local. A melhor classificação benigno versus maligno obteve 82,1% de acerto total, com uma área (A_z) de 0,85 sob a curva ROC. Foi obtido com as imagens do banco de dados do MIAS usando características de textura baseadas na SGLD calculadas das margens da massa e características baseadas no Gradiente $A_z = 0,6$ e $A_z = 0,76$ no banco de dados combinado (MIAS mais o banco de dados local).

O mesmo autor em 2001 (Mudigonda *et al.*, 2001) propôs um método para a descoberta de massas dentro de imagens mamográficas, que empregam operações de suavização gaussiana e subamostragem como passos de pré-processamento.

O processo de detecção do contorno da mama foi limitado a somente a região da mama. Um esboço aproximado da mama é descoberto inicialmente. A imagem é analisada com um núcleo de Gaussianas separáveis de 15 *pixels* de largura (1 *pixel* 200 μm) e reduzido a um máximo de 64 níveis cinzas. Nesse trabalho, a largura especificada para um núcleo de Gaussianas recorre à largura total de seu apoio e não à largura máxima da meia altura.

Um mapa de contornos de iso-intensidade é gerado através de limiarização da imagem que usa um limiar perto de zero. Do mapa de contornos de iso-intensidade, um conjunto de contornos é identificado empregando princípios de código de cadeia (Gonzales & Woods, 2002). Nesse estudo é considerado, então, que o contorno que contém a maior área é o esboço da mama.

A Figura 5.7 ilustra um mamograma com um tumor espicular maligno e a Figura 5.8 mostra os contornos da mama descobertos pelo método proposto. O método descobriu os esboços de todas as 56 imagens testadas no estudo.

Figura 5.7 - Um mamograma (tamanho 1024 x 1024 *pixels*, 200 m/*pixel*) com um tumor espicular maligno (Mudigonda *et al.*, 2001).

Figura 5.8 - O mapa de contornos de iso-intensidade extraído do mamograma mostrado na Figura 5.7 o contorno da mama descoberto.

O método foi introduzido para analisar fluxo orientado como informação textural em mamogramas. Os atributos baseados em orientação de fluxo em tiras adaptáveis de *pixels* pelas margens das massas são propostos para classificar as regiões detectadas como massas verdadeiras positivas (VP) ou falsas positivas (FP).

Com os métodos, foi feita a classificação das imagens em duas classes: massas e tecidos, resultando em A_z de 0,87 sob a curva ROC, com um grupo de dados de 56 imagens, incluindo 30 benignas e 13 malignas, e 13 casos normais selecionados do banco de dados da *Mammographic Image Analysis Society* (MIAS). Foi atingida uma sensibilidade de 81% com 2,2 FPs/imagem. A classificação de tumores malignos e tecidos normais obteve área sob a curva ROC de 0,9 usando só os 13 casos malignos e 13 casos normais, com uma sensibilidade de 85% e 2,45 FPs/imagem. O algoritmo de detecção de massa pôde encontrar todos os 13 tumores malignos com sucesso, mas só alcançou uma taxa de sucesso de 63% na detecção das massas benignas.

As regiões de massa que foram segmentadas com sucesso foram posteriormente classificadas como doenças benignas ou malignas, calculando cinco atributos de textura baseados em matrizes de co-ocorrência de nível-cinza SGLD e usando os atributos de características em um método de regressão logística. As características eram calculadas usando tiras adaptáveis de *pixels* pelos limites das massas. A classificação de massas benignas e malignas que usa a base SGLD de atributos de textura resultou em $A_z = 0,79$ com 19 benignos e 13 casos malignos.

Para Li *et al.* (Li *et al.*, 2001) a alta taxa de falso-positivo (FP) é um dos problemas principais para ser resolvido em estudo de CAD porque muitos sinais de falso-positivo podem degradar o desempenho de regiões verdadeiras positivas e aumenta a taxa de reamostragem em ambiente de CAD. Neste trabalho, Li *et al.* propuseram um método de classificação moderno para redução de FP, onde o classificador de decisão convencional mais rígido, utilizando método de árvore de decisão *fuzzy*, é substituído por uma classificação de decisão mais flexível, utilizando uma Rede Neural de Classificação Competitiva (CCNN - *Competitive Classification Neural Network*), com o objetivo de reduzir falsos positivos nos casos com taxa de FPs.

A CCNN é uma rede neural *feed-forward* de quatro camadas com pesos fixos e neurônios adaptáveis. As quatro camadas são descritas como segue:

Camada 1: recebe característica de entrada. Cada região tem um vetor de característica. Os componentes são individualmente alimentados na próxima camada, de forma que eles podem ser avaliados junto com o componente correspondente de outras regiões na posição competitiva subsequente.

Camada 2: classificação competitiva. É usada para determinar se a região é o topo da classificação, K_0 , de todas as regiões de entrada baseado em característica competitivas individuais, onde K_0 é o valor do limiar da função bi-polar de neurônio (*bias*). Para cada região, há N especialistas que classificam a saída dando um *ranking* de regiões suspeitas.

Camada 3: região de decisão. A saída de características individuais de classificação são entradas para a camada 3 para classificação de região. O neurônio desta camada tem uma função com um limiar C_0 , que é um limiar de decisão.

Camada 4: decisão da imagem. É uma camada opcional. É projetada para ser controlada de uma decisão *feedback* para limitar o número máximo por imagem, que é fixado para ser o limiar do neurônio de saída. Controla os limiares de neurônio na camada 2 (K_0) e na camada 3 (C_0).

O método de pré-classificação demonstrou a eficiência da estratégia de classificação proposta. Em média a redução de FP através de classificação híbrida mais rígida ou suaves é de 1,58 por imagem comparada a 1,11 através de classificação suave nos custos de VP descritos acima. Os casos com tecido denso apresentam maior risco de incidência de câncer, o que, porém aumenta as taxas de mamogramas falsos negativos, e normalmente gera mais FPs por esquemas CAD, o método proposto neste trabalho é mais

uma tentativa de melhorar a detecção precoce do câncer de mama através dos esquemas CADs.

Um estudo realizado por Georgiou et al. (2002) trabalhou com a análise aproximada das características morfológicas de forma de massas mamográficas. Foram exploradas três áreas distintas da forma morfológica para extração de atributos.

Especificamente, o sinal da distância radial, em que cada função da distância é calculada para detectar o centro da massa. Então, conforme pode ser visualizado na Figura 5.9, o centro da massa é definido como o centro de um sistema de coordenadas polares para uma específica resolução angular (N) e a linha da borda da massa é amostrada sobre $2/N$ intervalos para extrair a sequência da distância radial iniciando a partir do ângulo 0° . Todos os sinais das distâncias radiais foram normalizados utilizando valores mínimos e máximos ordenados para evitar excessivas diferenças em magnitude e energia entre massas de diferentes tamanhos.

Figura 5.9 - Extração do sinal da distancia radial: (a) detecção das bordas da massa, (b) amostra das massas do perímetro radial, (c) normalização do perímetro da massa, (d) Normalização do sinal da distância radial (Georgiou *et al.*, 2002).

O espectro DFT (Transformada Discreta de Fourier) e a DWT (Transformada Discreta *Wavelets*) foram analisados por sete funções de característica de curva, como portadoras de informação distintas significantes. As sete características de curva utilizadas neste estudo foram: (i) distância radial média, (ii) desvio padrão da distância radial, (iii) circularidade do tumor, (iv) entropia do histograma da distância radial, (v) relação dos parâmetros da área, (vi) contador de passagem por zero e (vii) aspereza da borda do tumor. A área foi calculada como a integral da normalização do sinal da distância radial, enquanto o perímetro foi extraído por somatório das diferenças entre todos os exemplos

seqüencialmente. A entropia (E) da distância radial foi calculada pela normalização do histograma da distância radial com $N=100$ colunas do histograma (*bins*) para estimar a aspereza da borda do tumor, e um valor fixo de segmentação com tamanho $L=16$, sendo L a quantidade de raios, foi experimentalmente determinado.

A classificação foi administrada para a identificação de tipo de forma morfológica, como também a verificação do diagnóstico clínico, usando característica aperfeiçoada, fixando seleções e combinações através de análise estatística multivariadas.

Neste estudo, ao invés de criar um módulo de máxima representação da produção de sinal por decomposição de *Wavelet*, cada componente foi tratada como um sinal separado. Em relação ao sinal original da distância radial, cada nível de decomposição deve capturar diferentes aspectos qualitativos e quantitativos das bordas do tumor e assim produzir detalhadas informações discriminantes.

Para calcular o efeito da seleção da função *Wavelet* sobre o poder distintivo discriminativo das características da curva calculadas em cada caso, várias funções *Wavelet* foram aplicadas no processo de decomposição das *Wavelet*. Especificamente, foram selecionadas cinco funções de *Wavelets*: (i) Haar, (ii) Sym2, (iii) Coiflet-1, (iv) Biorthogonal-1.5 e (v) discrete Meyer.

Foram utilizados 130 mamogramas para os testes. Para todo o grupo de dados disponível e configurações, foi aplicada uma gama extensiva de classificadores lineares e neurais, incluindo análise de discriminante linear (LDA), mínima distância quadrática (LSMD), K-vizinhos mais próximo (KNN), redes neurais RBF e MLP. Os classificadores neurais ultrapassaram a taxa de acerto em todos os casos, produzindo uma precisão global de 72,3% para identificação de tipo de forma e 89,2% para identificação de diagnóstico clínico.

Segundo Mavroforakis *et al.* (2002) a análise de textura é um dos fatores mais importantes em caracterização de tecido da mama. Uma aproximação analítica para classificação de textura, combinou com dados de diagnóstico descritivos e qualitativos. Para dados qualitativos, uma aproximação estatística foi aplicada a resultados clínicos e características relacionadas à textura foram estabelecidas, a partir do grau de importância, durante o processo de confirmação do diagnóstico. Um grupo completo de característica de textura foi aplicado a um conjunto grande de mamogramas digitalizados.

Múltiplos modelos lineares e não lineares foram aplicados durante o processo de classificação, incluindo LDA, classificador de mínima distância quadrática (LSMD), K vizinhos mais próximos (KNN) (Mitchell, 1997), RBF e MLP.

Para estudar o efeito relativo na qualidade da informação de textura extraída das imagens digitalizadas, um grupo grande de técnicas de extração de atributos foi aplicado. Para cada amostra de matrizes de sub-regiões, co-ocorrência e matriz *run-length* (matriz de comprimento variado) foram calculadas para três configurações separadas de vizinhança de *pixel* de acordo com um fator de distância $d = \{1,2,3\}$, criando três esquemas, como mostra a Figura 5.10.

Figure 5.10 - Sub-regiões de amostra de esquemas sob várias vizinhanças de *pixel* de: (a) $d=1$, (b) $d=2$ e (c) $d=3$.

De cada amostra de sub-regiões, foram extraídos atributos de textura:

Estatística de primeira ordem, onde a distribuição de níveis de cinza para cada matriz de sub-regiões da imagem foi examinada por seis métricas propostas por Haralick (Haralick *et al.*, 1973). Isto é, mínimo valor, máximo valor, valor médio, desvio padrão, *skewness* e *kurtosis* foram usados como medidas descritivas dos níveis de cinza.

Estatística de segunda ordem, onde a distribuição de níveis de cinza derivou da matriz de distribuição espacial de níveis de cinza (SGLD – *Spatial Grey-Level Dependence*), matriz de co-ocorrência que “mede” o conteúdo de informação de textura, e foi extraída por 14 medidas propostas por Haralick (Haralick *et al.*, 1973), isto é, Energia ou Uniformidade, Contraste, Correlação, Variância, Momento da diferença inversa, Média da Soma, Variância da Soma, Entropia da Soma, Entropia, Variância da Diferença, Entropia da Diferença, Medida de Informação de correlação 1, Medida de Informação de correlação 2 e Máximo Coeficiente de Correlação.

A variação do nível de cinza, derivada de matrizes de *run-length* (RML) (matriz de comprimento variado), foi examinada por cinco métricas de *run-length* propostas por Galloway (Galloway, 1975): variação curta de ênfases (*short runs emphasis*), variação longa de ênfases (*long runs emphasis*), comprimento variado não uniforme (*run-length non-uniformity*) e variação de porcentagens (*run percentage*) foram usados como medidas de descrição de cada matriz de *run-length* calculado sobre a amostra das sub-regiões da imagem.

Vários classificadores foram aplicados durante a fase de classificação. Um modelo LDA foi usado como classificador linear. Um classificador de mínima distância quadrática (LSMD) foi utilizado, usando medidas de distância Mahalanobis (Mascarenhas & Velasco, 1989). Um vizinho mais próximo (KNN) também foi utilizado incluindo estimativas do melhor valor de K para o tamanho do grupo de vizinhança. Dois diferentes tipos de arquitetura de redes neurais foram utilizados, uma rede RBF com Gaussiana como função de ativação e função linear de saída, e uma rede MLP com tangente hiperbólica como função de ativação. Todas as configurações utilizaram o método *leave-one-out* (Hertz *et al.*, 1991; Haykin, 1994) durante a fase de treinamento e teste.

Os testes de classificação foram realizados em quatro fases:

- Avaliação do conteúdo discriminado dos dados qualitativos utilizando características de forma. Foi estatisticamente verificado que formas redondas e lobulares apresentaram somente 5% a 16% de malignidade, enquanto irregular e espiculado apresentaram 90% a 97% de malignidade. Isso mostra que características de forma com medidas discriminantes podem estabelecer acerto entre casos benignos e malignos numa taxa de 90% de acerto.
- Estudo do efeito das diferentes características de texturas usando todas as outras características menos a forma da massa e a idade da paciente. O classificador LSMD obteve 86,9% de acerto. Incluindo a idade de pacientes nestas características, o de precisão foi de 89,2%. Acrescentando o tipo de forma, as taxas de precisão variaram de 87,7% até 91,5% para o grupo de dados sem referência, enquanto para o grupo de dados “informações do tipo de massas”, as taxas de precisão variaram de 91,5% até 93,1%.
- Avaliação do conteúdo obtidos pelos vários atributos de textura. Foram realizados quatro testes sendo que a primeira configuração incluiu exemplos com vizinhança de 50 *pixels* para as três distâncias ($d = 1,2,3$) utilizando LDA e classificador de mínima distância quadrática (LSMD) com uma taxa de acerto de 72,6%. A segunda configuração utilizou distância de vizinhança de *pixels* ($d = 1$); neste caso a melhor taxa foi de 67,5% utilizando LDA. Na terceira configuração todas as três distâncias foram avaliadas ($d = 1,2,3$) sendo a melhor taxa de acerto de 58,3% para LSMD e na quarta configuração, com distância de vizinhança de *pixel* ($d = 1$), a melhor taxa foi 65,8% para LSMD.
- Uma configuração híbrida misturando dados qualitativos e atributos de textura foi utilizada para construir a base de dados para avaliar sua utilidade em aplicações

diagnósticas práticas com a utilização de classificadores robustos, dentre eles MLP e LSMD, em ambos os casos a taxa de acerto para somente textura ficou em 81%, e 85% quando foram utilizados os atributos de textura mais a idade da paciente.

Segundo o autor (Mavroforakis *et al.*, 2002) a análise de textura é uma das mais valiosas e promissoras áreas em análise de características de tecido da mama. Os atributos de textura foram extensamente usados para uma variedade de aplicações de visão computacional, inclusive sistemas diagnósticos para imagens de ultra-som e segmentação de imagens mamográficas.

André e Rangayyan (André & Rangayyan, 2003) propuseram uma aproximação que usa redes neurais artificiais para classificar massas em mamogramas como maligna ou benigna. A rede Perceptron Multi-Camadas, com uma única camada foi usada em um estudo para classificação de padrão de massas de mama.

Dois conjuntos de imagens de mamografias digitalizadas foram usadas no estudo. O primeiro grupo contendo 54 imagens, incluiu regiões de interesse (RIs), sendo 28 com massas benignas e 26 tumores malignos. O segundo conjunto continha 34 massas benignas e 20 tumores malignos. O diagnóstico de cada caso foi comprovado através de biópsia. Massa ou tumor foram identificados em RIs manualmente e contornos eram identificados nas imagens digitais por um especialista. As bordas de 108 massas e tumores foram delimitadas e representadas por modelos poligonais para análise de forma.

Três características de forma foram calculadas para cada contorno:

(a) Compacidade, que é uma medida simples de complexidade de forma, e pode ser representada em uma forma normalizada como $C = 1 - 4\pi A/P^2$, onde A é a área e P é o perímetro do contorno;

(b) Concavidade fracionária, F_{cc} , que é a relação entre comprimento cumulativo das porções côncavas do contorno e o comprimento total do contorno;

(c) Índice de Espicularidade, SI , que representa o grau de espicularidade de um contorno de massa. Rangayyan *et al.* (Rangayyan *et al.*, 2000) propuseram um algoritmo para calcular SI fundado em um modelo poligonal de determinado contorno e uma combinação dos comprimentos de segmento, larguras básicas e ângulos de possíveis espículas.

Atributos de textura foram calculados usando margens de massa, definidas como tiras que cercam a massa da RI, e não a região inteira. Esta aproximação segue Mudigonda *et al.* (Mudigonda *et al.*, 2000), que usaram margens das massas para melhorar a discriminação entre massas benignas e malignas quando comparadas com as mesmas medidas calculadas usando as regiões inteiras. Uma simples combinação da matriz de co-

ocorrência de níveis de cinza foi calculada usando 4 *pixels* conectados. Os atributos de textura foram calculadas de acordo com Haralick *et al.* (Haralick *et al.*, 1973; 1979).

Várias combinações de atributos e várias topologias foram usadas com Perceptron para classificação de massas em benignas e malignas. Os resultados foram comparados em termos da área (A_z) sob a curva ROC. Os valores de $A_z = 0,99$ foram obtidos com os atributos de forma, considerando que atributos de textura obtiveram $A_z = 0,63$.

No trabalho de Arbach *et al.* (Arbach *et al.*, 2003) foi comparada a performance da classificação mamográfica entre uma rede neural backpropagation (BNN), método dos K vizinhos mais próximos (KNN), radiologistas especialistas e residentes. A meta do trabalho era reduzir falsos negativos durante as leituras dos mamogramas.

Foram utilizados 160 casos contendo pelo menos uma massa acompanhada de uma biópsia. As massas foram extraídas usando regiões que crescem com sementes locais identificadas por um radiologista especialista. Foram extraídas das imagens 10 características de formas e texturas: área, perímetro, densidade, comprimento radial, espicularidade, média e desvio-padrão de comprimento radial normalizado, comprimento de mínimo e máximo, e aspereza de limite, que foram usadas como entradas para uma BNN e um KNN. Dos 160 casos, 140 foram usados para treinar a BNN e o KNN e os 20 casos restantes foram usados para testes.

Os conjuntos de testes foram diagnosticados por três radiologistas especialistas, três residentes, a BNN e o KNN. Foram avaliadas as leituras dos especialistas e da BNN, calculando a área sob a curva ROC. O KNN foi avaliado através da sensibilidade, especificidade e número de falsos negativos (FN).

A área sob a curva ROC foi de 0,923 para a BNN, 0,846 para os radiologistas experientes e 0,648 para os residentes. O KNN teve uma especificidade de 85,7% com sensibilidade 84,6%. Estes resultados usam a BNN como o assistente de um médico para classificação de massa de mama.

O propósito do estudo realizado por Markey *et al.* (Markey *et al.*, 2003) foi identificar e caracterizar conjuntos em uma base de dados de câncer de mama através de esquemas CAD, onde a identificação de subgrupos dentro do banco de dados poderia ajudar a definir tendências euclidianas e facilitaria modelos futuros. Um Mapa Auto-Organizável (SOM – *Self-Organizing Map*) foi usado para identificar conjuntos dentro de um grande banco de dados contendo 2258 casos heterogêneos baseados em resultados das mamografias, segundo a padronização BI-RADS e idade da paciente. Os conjuntos

mostraram separação lógica de subtipos clínicos como distorções arquitetônicas, massas, e calcificações. Além disso, foram extraídas as várias características de massas e calcificações em vários subgrupos formados por sete grupos para massas e três para calcificações.

A porcentagem dos casos que eram malignos foi notavelmente diferente entre os subconjuntos, variando de 6 a 83%. Uma rede neural artificial *backpropagation* foi utilizada para identificar lesões benignas que provavelmente podem ser candidatas a biópsia. O desempenho da Rede *Backpropagation* variou consideravelmente em relação aos conjuntos identificados pelo SOM. A Rede Neural *Backpropagation* obteve aproximadamente 25% de especificidade a 98% sensibilidade. Este desempenho foi demonstrado para generalizar um grande conjunto de dados com 2177 casos para validação modelo.

Segundo os estudos realizados por Rangayyan e Nguyen (Rangayyan & Nguyen, 2005), as massas das mamas podem ser classificadas como benignas ou malignas baseadas na forma e em características de texturas em imagens de mamografia. As massas benignas são geralmente lisas, circunscritas e os contornos são bem definidos, considerando que tumores malignos são geralmente ásperos, espiculados e com contornos mal-definidos. Fundados nestas observações atributos de forma como Compacidade (C), Índice de Espicularidade (SI), Concavidade Fracionária (Fcc), Fatores de Fourier (FF), e Dimensão de Fractal (FD) foram extraídos. O foco deste estudo foi aplicar um método de classificação de padrão como também a análise ROC para avaliar o desempenho de classificação de cada atributo de forma e várias combinações dos atributos de forma. Mais especificamente, estudar o desempenho da FD, classificando massas de mama, em comparação e conjunção com os outros atributos de forma mencionados acima.

Três grupos de dados de contornos de massas de mama foram usados neste estudo. O primeiro grupo de dados continha 37 contornos de massas benignas, a maioria circunscrita (CB), e 20 contornos de tumores malignos, a maioria dos quais espiculados (SM). O segundo grupo de dados incluiu contornos circunscritos e espiculados com ambas as categorias benignas e malignas. Espiculares benignos (SB) e circunscritos malignos (CM) são casos insólitos, e tendem a causar dificuldades em estudos de classificação de padrão, tendo um total de 54 contornos incluindo 16 CB, 12 SB, 19 SM, e 7 CM. O terceiro grupo combinou dados do primeiro e segundo grupos de dados num total de 111 contornos que incluíram formas típicas e atípicas de 65 massas benignas e 46 tumores malignos.

Em geral, o uso de múltiplos atributos de forma conduziu à classificação de padrões mais precisos, indicados por valores de A_z mais altos, que o uso de um único

atributo de forma. Combinando diferentes atributos de forma, as mais significantes compensam as menos significantes.

Com base na Tabela 5.1, foi possível verificar que considerando o uso de um único atributo de forma (Fcc) alcançou-se uma classificação mais precisa com A_z igual a 0,99. Com os outros quatro atributos de forma (C, SI, FF, e FD) também foram obtidos bons resultados com A_z variando de 0,93 a 0,98.

Tabela 5.1 - Precisões de classificação para algumas combinações de características de forma em termos da área sob a curva de ROC (Rangayyan & Nguyen, 2005).

Características de forma	Grupo de dados #1 A_z	Grupo de dados #2 A_z	Grupo de dados #3 A_z
FD, FCC	0,99	0,80	0,93
FD, Fcc, SI	0,99	0,80	0,92
Fcc, SI	0,99	0,77	0,92
FD, SI	0,96	0,84	0,91
SI	0,93	0,77	0,90
Fcc	0,99	0,77	0,88
FD	0,93	0,78	0,88
C	0,97	0,72	0,87
FF	0,98	0,65	0,77

Todos os atributos de forma, com exceção de FF puderam classificar o CB típico e tumores SM com precisão. Porém, a maioria dos atributos de forma não puderam classificar os casos atípicos de massas de SB e tumores CM corretamente. Com um grupo de dados combinado que incluiu 111 contornos de uma combinação de massas típicas e atípicas e tumores, foi descrito que a associação de dois ou mais atributos de forma pôde alcançar melhores desempenhos que qualquer atributo de forma isolado na classificação de massas de mama.

Segundo Mavroforakis (Mavroforakis *et al.*, 2005), os avanços em tecnologias modernas e computadores habilitados a processar imagem digital se tornaram uma ferramenta vital na prática clínica convencional, inclusive mamografia. Porém, o problema central da avaliação clínica de tumores em mamografia está no fato de ser uma tarefa cognitiva altamente exigente. Para que estes sistemas de diagnósticos automatizados trabalhem com níveis de sensibilidade e especificidade semelhantes aos especialistas humanos, é essencial que uma estrutura robusta seja formulada.

No estudo de Mavroforakis (Mavroforakis *et al.*, 2005) foi focalizada a identificação de um grupo robusto de características clínicas que podem ser usadas como base para projetar a contribuição de qualquer esquema de *Computer-Aided Diagnosis* (CAD)

para avaliação de tumores mamográficos automaticamente. Uma lista completa com 31 características clínicas foi elaborada e o valor diagnóstico de cada característica foi verificado com base nas práticas clínicas por um médico especialista. Estas características foram direta ou indiretamente relacionadas às propriedades morfológicas globais do tumor mamográfico ou à textura das estruturas de tecido e como ele se apresenta na imagem digitalizada, enquanto outras corresponderam a dados clínicos externos de importância, como a idade da paciente. O grupo formado por nove características clínicas: (1) a presença de tumores, (2) a presença de microcalcificações, (3) a densidade do tumor, (4) a porcentagem de gordura dentro do tumor, (5) a incerteza da borda do tumor, (6) a homogeneidade do tumor, (7) a morfologia do tipo de forma do tumor, (8) a idade da paciente e (9) o diagnóstico histológico final, foi usado como uma lista de anotação por descrever as propriedades clínicas dos casos de tumor mamográfico em um modo quantitativo, tal que análises objetivas subsequentes foram possíveis.

A partir desse estudo, foi criado um banco de dados mamográficos com 130 imagens sendo 46 benignas e 84 malignas, com a completa descrição da avaliação clínica e verificação histológica positiva para cada caso. Todos os tumores contidos no banco de dados foram caracterizados de acordo com o grupo identificado nas características clínicas e o resultado do grupo de dados foi usado como contribuição para discriminação e análise de valor de diagnóstico para cada uma destas características. Especificamente, foram empregadas várias metodologias padrões de análise de significação estatística para criar posições de característica de acordo com o poder discriminante, Figura 5.11.

Figura 5.11 - Interferência entre as duas curvas de distribuição normais à probabilidade de erro estatística devido a *aliasing* entre as duas classes. O verdadeiro erro de *aliasing* era calculado aplicando o limiar de decisão específico para indicador de limite de borda no grupo de 130 imagens mamográficas (Mavroforakis *et al.*, 2005).

Além da análise estatística, três diferentes modelos de classificação, foram empregados:

- Classificadores lineares: *Linear Discrimination Analysis* (LDA) (Lanchenbruch, 1975) aplicado na forma de classificação utilizando subconjuntos iterativos de treinamento inicial, empregando a classificação *leave-one-out* (Hertz, 1991; Haykin, 1994) para todo padrão individual do grupo; *Minimum Distance Classifier* (MDC) (Gose *et al.*, 1996) com distância Mahalanobis (Mascarenhas & Velasco, 1989), empregada em combinação com dados da transformação do mínimo quadrado para a melhor densidade estatística, produzindo o classificador de mínima distância quadrática (LSMD) (Fukunaga, 1990).
- Redes neurais: uma *Multi-Layer Perceptron* (MLP) (Hertz, 1991; Haykin, 1994) usando o algoritmo de *backpropagation* para treinamento; e uma rede neural *Radial Basis Function* (RBF) (Hertz, 1991; Haykin, 1994).
- *Support Vector Machine* (SVM) (Mitchell, 1997) que foi aplicada em relação ao diagnóstico final. Especificamente, o modelo C-SVC, da família do classificador SVM, (Mavroforakis *et al.*, 2005) foi utilizado em combinação com a RBF.

Ambos resultados estatístico e de classificação provaram a correlação explícita de todas as características selecionadas com o diagnóstico final, como uma base de contribuição adequada para qualquer tipo de sistema de diagnóstico semelhante automatizado. A complexidade subjacente da tarefa de diagnosticar justificou o alto valor de arquiteturas sofisticadas de reconhecimento de padrão. Segundo o autor, o melhor grupo de características, Tabela 5.2, foi o SVM, que produziu taxa de precisão de quase 95%, plausível para aplicação em clínicas. Todas as características investigadas nesse estudo, menos a idade da paciente, são relacionadas com morfologia e propriedades de textura da própria imagem mamográfica. Logo, um sistema de diagnóstico completamente automatizado é possível, usando as mesmas características descritivas.

Tabela 5.2 - Taxa de Sucesso de todos os classificadores CAD, com e sem contribuição de tipo de forma.

Modelos de Classificação	Precisão sem informação de tipo de forma	Precisão informando tipo de forma
Objetivo: diagnóstico de tumor		
LDA	87,69%	93,85%
K-NN	91,54%	93,08%
LSMD	89,23%	93,08%
MLP	91,54%	91,54%
RBF	90,77%	91,54%
C-SVC/RBF	93,85%	94,62%

6 - MATERIAIS E MÉTODOS

Este trabalho foi dividido em vários experimentos com o objetivo de uma maior investigação em busca do reconhecimento dos cinco possíveis contornos de nódulos mamários. Para isso, várias técnicas de extração de atributos foram estudadas, para que se obtivessem atributos significativos para uma melhor classificação das Regiões de Interesse (RIs), pois o desempenho do classificador, neste caso, as RNAs, depende de dois estágios anteriores ao processo de classificação: a aquisição do padrão e a extração e seleção de atributos que melhor representem cada classe (Duda *et al.*, 1979).

Os experimentos foram divididos em duas fases: a primeira com o objetivo de validação das Redes Neurais e os descritores de textura; a segunda, visando a aplicação dessas técnicas validadas, de outras já desenvolvidas anteriormente (Santos *et al.*, 2002; Patrocínio, 2004), e com a análise dos atributos resultantes. A finalidade de tal análise é selecionar os mais significativos para servir de entrada para duas Redes Neurais, uma Rede MLP, (supervisionada) e uma SOM (não-supervisionada). Com base nos resultados dos treinamentos, a intenção era encontrar o mais confiável para compor um novo módulo do classificador implementado no esquema CAD em desenvolvido em nosso grupo⁷.

6.1 - Extração de atributos

Existem diversas técnicas de extração de atributos, ou características, utilizados por classificadores automáticos de esquemas CAD, conforme já discutido no Capítulo 5.

⁷(Nunes, 2001; Santos *et al.*, 2002; Lagoeiro, 2004; Patrocínio, 2004; Vieira, 2005).

Neste trabalho procurou-se aplicar algumas técnicas específicas, como: Descritores de Textura, de Intensidade e Geométricos, com o objetivo de selecionar os mais significantes e que melhor caracterizassem as cinco classes a serem diferenciadas pelo sistema classificador aqui proposto, utilizando o nosso conjunto de imagens. A seguir serão apresentados os descritores estudados. A codificação dos algoritmos foi realizada utilizando o ambiente de desenvolvimento *Borland Delphi 7* para plataforma *Microsoft Windows*.

6.1.1 - Descritores de Textura de Haralick

A textura possui três abordagens principais utilizadas em processamento de imagens (Gonzalez & Woods, 2000), sendo elas: abordagem estrutural, abordagem espectral e abordagem estatística. Neste trabalho será dada ênfase à abordagem estatística, através dos descritores de textura de Haralick (Haralick *et al.*, 1979) utilizando-se da matriz de co-ocorrência de níveis de cinza (SGLD – *Spatial Grey-Level Dependence*) para calcular a probabilidade de ocorrência combinada de direção e distância entre pares de *pixels* com valores de intensidade semelhantes. Embora não exista uma definição formal, os descritores de textura fornecem medidas de propriedades como suavidade, rugosidade e regularidade.

Para a extração dos 14 atributos de textura sugeridos por Haralick (Haralick *et al.*, 1973), segundo equacionamento descrito no Capítulo 3, e para uma melhor visualização dos dados, foi desenvolvida uma interface gráfica. Essa interface pode ser visualizada através da Figura 6.1. Seu funcionamento segue as seguintes instruções: ao pressionar o botão “Abrir”, será apresentada uma lista de imagens a serem selecionadas. O objetivo desse botão é propiciar a seleção de uma ou várias imagens. Após a seleção, a imagem ou todas as imagens serão apresentadas na primeira coluna da grade, com subsequente habilitação do botão “Haralick” para que se possam extrair as características que também serão apresentadas na grade. O botão “Novo” tem a função de “limpar” a grade de informações, assim como a imagem localizada na tela. No momento do pressionamento do botão “Haralick”, o algoritmo irá apresentar a imagem na tela e gravar o valor dos atributos extraídos na grade. Depois de todas as características serem extraídas, será possível salvar esses atributos de textura em arquivo texto, sendo utilizado posteriormente como entrada para o classificador.

Figura 6.1 - Interface desenvolvida para extração de atributos de Haralick.

6.1.2 - Descritores de Intensidade

Como pretende-se acrescentar o módulo resultante dessa pesquisa ao classificador geral do Esquema CAD em desenvolvimento na equipe do LAPIMO, serão utilizadas algumas técnicas já desenvolvidos em trabalhos anteriores, como os Descritores de Intensidade, implementados por Patrocínio (Patrocínio, 2004), com o objetivo de classificar densidades e estabelecer a categoria BI-RADS do caso em análise.

Segundo Patrocínio (Patrocínio, 2004), na imagem digitalizada, a variação de densidade óptica está relacionada com a intensidade de *pixels*; logo, a escala de níveis de cinza é um fator relevante nessa análise.

Considerando que as imagens podem ter sido digitalizadas em mais de um digitalizador, foi feita uma normalização antes que elas fossem submetidas aos procedimentos de extração de atributos de intensidade. Com a imagem corrigida, pode-se

admitir que as diferenças de escalas efetivas de resolução de contraste não vão influenciar na análise dos atributos extraídos das imagens em níveis de cinza, pois os valores de intensidade de *pixel* são relativos à escala, teoricamente, de 12 bits, ou seja, 4096 níveis.

Para o cálculo da variação de níveis de cinza numa região de interesse, foi desenvolvida uma rotina de varredura *pixel a pixel* da imagem. Assim, é possível encontrar os *pixels* de menor e maior intensidade da região. Os *pixels* de menor intensidade geralmente estão associados a tecidos gordurosos (Wang, 2003), e os de maior intensidade a tecidos mais densos (fibroglandulares) ou a lesões.

Através da interface da Figura 6.2 (Patrocínio, 2004), é possível verificar o histograma da imagem e os descritores de intensidade extraídos. O funcionamento da etapa de extração de atributos de intensidade segue as seguintes instruções: ao pressionar no botão “Abrir”, será apresentada uma lista de imagens a serem selecionadas; o sistema irá abrir uma imagem a cada processo de extração de descritores de Intensidade. Após a imagem aberta, deve-se pressionar o botão “Calcular Características em Imagens em Tons de Cinza”. A partir daí, serão realizadas as correções na imagem, o cálculo do histograma e a extração dos descritores de intensidade.

Figura 6.2 - Interface de extração de atributos de intensidade (Patrocínio, 2004).

6.1.3 - Descritores Geométricos

Para a obtenção dos descritores geométricos, novamente, são utilizados outros trabalhos já desenvolvidos pelo LAPIMO, para o desenvolvimento do Esquema CAD.

O primeiro foi desenvolvido por Santos (Santos *et al.*, 2002) e tem como objetivo a detecção do nódulo e segmentação com base na técnica da Transformada *Watershed*. Segundo Santos (Santos *et al.*, 2002) o esquema computacional de detecção de nódulos segue os seguintes passos:

- Cálculo do gradiente interno (objeto) e externo (fundo) para toda imagem;
- Cálculo e armazenamento dos *pixels* mais brilhantes, (pontos de mínimo), que serão os marcadores da imagem;
- Inversão do gradiente e cálculo de distâncias *Hit-and-Miss*: elimina o objeto para trabalhar com o fundo; Sequência de *thinning* no fundo; SKIZ: *tickening* no 1º plano, para montar o esqueleto através da análise da vizinhança, eliminando pontos e gerando as zonas de influência. Utilizando-se o valor absoluto do gradiente, constrói-se uma espécie de “topografia” (regiões homogêneas compõem as regiões planas da “topografia”);
- “Inundação das regiões baixas”, a partir dos pontos de mínimo agindo como pontos sementes para o crescimento de regiões, onde a parada é o gradiente da imagem;
- Formação, através das áreas marcadas com diferentes “níveis de água”, dos segmentos separados pelas linhas da transformada *Watershed*, conforme pode ser visualizado na Figura 6.3 (Santos *et al.*, 2002);
- Binarização da imagem e destaque do nódulo em relação ao restante da imagem, conforme a Figura 6.4 (Santos *et al.*, 2002).

Figura 6.3 - Imagem com as linhas de *Watershed* e junção com a imagem original (Santos *et al.*, 2002).

Figura 6.4 - Imagem segmentada e seu contorno (Santos *et al.*, 2002).

Um segundo procedimento utilizado (Patrocínio, 2004), a partir das imagens resultantes do trabalho de Santos (Santos *et al.*, 2002), extrair os descritores geométricos. Ou seja, a partir das imagens binarizadas contendo nódulos, são calculados: os momentos cartesianos, os Momentos Invariantes de Hu, o Raio de Giração (RG), perímetro, área, compacidade e irregularidade (já comentados no Capítulo 3).

Na Figura 6.5 (Patrocínio, 2004), é possível visualizar a imagem binarizada e os descritores geométricos. O funcionamento da extração de atributos geométricos segue as seguintes instruções: ao pressionar o botão “Abrir”, será apresentada uma lista de imagens já segmentadas a serem selecionadas; o sistema irá abrir uma imagem a cada processo de

extração de descritores de Intensidade. Após a imagem aberta, deve-se pressionar o botão “Calcular em Imagem Segmentada” e, a partir daí, será realizada a extração dos descritores geométricos.

Figura 6.5 - Interface de extração de atributos geométricos (Patrocínio, 2004).

6.1.4 - Utilização de todos os Descritores

Após os estudos realizados com todas as técnicas, foi desenvolvida uma interface para facilitar a extração de todos os descritores de todas as RIs selecionadas. Para isso foi utilizada a interface da Figura 6.6, que passou por algumas alterações e foi adaptada para a construção da tela do classificador final.

Através dessa interface, é possível extrair todos os descritores e salvá-los em arquivo texto, que posteriormente servirá de entrada para duas Redes Neurais, uma Rede MLP e outra SOM. O funcionamento da extração de todos os atributos segue as seguintes instruções: ao pressionar o botão “Abrir” - referente tanto às imagens originais, ou seja,

que não passaram por nenhum processamento, como às imagens segmentadas (Santos *et al.*, 2002) - será identificado o caminho onde estão as imagens da classe da qual se desejam extrair os descritores. Pressionando o botão “Descritores”, serão extraídos os descritores de textura, intensidade e geométricos de todos os pares de imagens original e segmentada e, após a extração, serão salvos em um arquivo texto.

Figura 6.6 - Interface utilizada para a extração de todos os atributos e que foi adaptada para a construção da tela do classificador final.

6.2 - Redes Neurais Artificiais

Para os testes, foram utilizadas duas RNAs, a Rede *Self-Organizing Map* (SOM), Figura 6.7, e a *Multi-Layer Perceptron* (MLP), Figura 6.8. Para uma melhor visualização dos dados foi desenvolvida uma interface gráfica para facilitar os treinamentos e testes realizados com os atributos extraídos das RIs.

Para a rede SOM, a interface gráfica, Figura 6.7, facilitou a visualização dos *clusters* referentes às classes que estão sendo estudadas, pois, com base na tabela de cores (localizada próximo ao centro da Figura 6.7), foi possível selecionar qual seria a cor dada a cada padrão de entrada da rede. Além das cores, é possível alterar o tamanho e a quantidade de neurônios do Mapa Bidimensional, o número de iterações, o raio de vizinhança (σ) e a taxa de aprendizagem (ξ) na fase de ordenação, e a convergência da rede. Após a leitura dos padrões de entrada da rede o botão “Kohonen” será habilitado. Porém, só apenas depois de pressionar este botão é que a rede será inicializada. Quando o final das iterações informadas é atingido pela rede, são apresentados no mapa bidimensional os nós com as respectivas cores dos padrões. A localização de cada entrada poderá ser feita através do botão “Resultados”, que irá apresentar uma grade contendo a ordem dos padrões que entraram na rede e a linha e coluna em que estes estão localizados no mapa bidimensional.

Figura 6.7 - Mapa Auto-Organizável de Kohonen.

A interface da rede MLP, Figura 6.8, apresenta uma série de parâmetros a serem informados, tais como: o número de camadas escondidas, o número de neurônios que serão utilizados para cada camada, a taxa de aprendizagem, constante momento, limiar, critério de parada com erro menor que um valor estipulado, número máximo de iterações (caso o erro menor não seja encontrado), a função de ativação que será utilizada no algoritmo, como os pesos devem ser iniciados e a localização do resultado desejado dos

padrões de entrada que estão sendo passados para a rede. Somente depois da informação de todos esses parâmetros e a entrada dos padrões, o treinamento poderá ser inicializado. Após a finalização do treinamento, o algoritmo irá apresentar o valor dos pesos de cada neurônio das camadas e, para visualizar os resultados, deverá ser pressionado o botão “Aplicar”, que irá apresentar os resultados de cada saída desejada em uma grade e, embaixo do botão “Aplicar”, a quantidade de acertos e erros de cada classe que está sendo investigada. Como exemplo de classe, podemos citar a existência ou não de nódulo em uma imagem.

Treinamento

No. de Camadas Escondidas: 1

No. de neurônios na camada de entrada: 6

No. de neurônios na 1o. camada escondida: 32

No. de neurônios na 2o. camada escondida: 0

No. de neurônios na camada de saída: 2

Taxa de aprendizagem: 0,5

Constante Momentum: 0,1

Threshold/Limiar: 0

Critério de parada ERRO: 0,09

No. Máximo de ciclos: 10000

Função de ativação:

- ☒ Sigmóide
- ☐ Tangente Hiperbólica
- ☐ PPS

Iniciar pesos:

- ☒ Aleatórios
- ☐ Iguais a zero

Sobre o Arquivo para Treinamento

Localização do resultado desejado:

- ☐ Última posição dos padrões de entrada
- ☒ Primeira posição dos padrões de entrada

Qtd. exemplares treinados: 90 Número de Ciclo ("epochs"): 798

G1 = 45G2 = 45G3 = 0 [Limpar] [Abrir Arq. Valid.] [Abrir Arq. Derm.] [Treinamento]

Valor dos Pesos - Entrada para a camada escondida

Ent./Esc.	1	2	3
bias	-2,2604466932995	-0,7730488653002	-0,07226
1	3,2272420654088	1,0180188551925	-0,03213
2	0,0574915048738	0,0993963139631	0,99633

Valor dos Pesos - Camada escondida 1 para camada escondida 2

Ent./Esc.	1	2	3
bias	-1,1816804869004	0,8112036247078	
1	1,6819323592133	-3,0486810777606	
2	0,3305865656449	-0,7066453190672	
3	-0,6065053949315	1,3199225443099	

Valor dos Pesos - Camada escondida 1/2 para camada saída

Esc./Sai.	1	2
bias	-1,1816804869004	0,8112036247078
1	1,6819323592133	-3,0486810777606
2	0,3305865656449	-0,7066453190672
3	-0,6065053949315	1,3199225443099

Resultados

Padrões	1	2	3	4
1	0,127338	0,882681	0,708002	2,377737
2	0,165437	0,419373	0,102614	1,146988
3	0,201062	0,643718	0,784892	2,510894
4	0,04005	0,071777	0,218861	1,69777
5	0,136745	0,494984	0,855453	2,625897
6	0,080186	0,11552	0,181204	1,542722
7	0,286982	0,855043	0,70663	2,376125
8	0,037604	0,174352	0,160688	1,450015

[Aplicar]

C.1: V = 37; F = 8
C.2: V = 43; F = 2

[Sair]

Figura 6.8 - Multi-Layer Perceptron (MLP).

Como foi pequeno o número de imagens obtidas com laudo de contorno para o treinamento através da técnica de *cross validation*, foi utilizada a técnica *leaving-one-out* (Hertz *et al.*, 1991; Haykin, 1994).

6.3 - A Base de Imagens Mamográficas

Os mamogramas utilizados para a realização do trabalho foram obtidos do Hospital das Clínicas de Ribeirão Preto (FMRP/USP), Hospital São Paulo (UNIFESP), Santa Casa de São Carlos e Hospital das Clínicas de Botucatu (UNESP), e as imagens digitalizadas estão armazenadas num banco de imagens mamográficas, que contém atualmente cerca de 6000 imagens, elaborado no LAPIMO (Laboratório de Análise e Processamento de Imagens Médicas e Odontológicas) do Departamento de Engenharia Elétrica EESC/USP, Figura 6.9. As imagens mamográficas foram digitalizadas em *scanners* laser Lumiscan 75 (imagens do HSP) e 50 (demais), com 12 bits de resolução de contraste (4096 níveis de cinza) e com resolução espacial de 0,15 mm por *pixel* e 0,075 mm para o HSP.

Figura 6.9 - Banco de Imagens Mamográficas.

6.4 - Análise dos Atributos

A análise dos atributos é muito importante para melhorar o desempenho do classificador. Três métodos foram utilizados nos testes para a seleção dos melhores atributos:

1) Distribuições Gaussianas: neste método quanto menor a sobreposição das curvas, melhor o atributo poderá representar cada padrão, conforme pode ser visualizado na Figura 6.10, onde a base da curva vermelha, que representa os casos normais (60 RIs com ausência de nódulo), não sobrepõe a curva azul, que indica a existência de nódulo (60 RIs com nódulo). Quanto maior essa sobreposição, porém, pior será a representação, conforme visualizado na Figura 6.11. Essa metodologia já foi utilizada por Patrocínio (Patrocínio *et al.*, 2000) anteriormente para seleção de atributos para classificação de microcalcificações utilizando Rede Neural Artificial MLP. Para os nossos experimentos, as distribuições gaussianas foram implementadas em Matlab 7.0.

Figura 6.10 - Distribuição Gaussiana sem a sobreposição das curvas.

Figura 6.11 - Distribuição Gaussiana com sobreposição completa das curvas.

2) *Self-Organizing Map* (SOM): Como essa RNA tem a propriedade de se auto-organizar e de extrair as características comuns dos padrões de entradas, ou seja, agrupar os

padrões com características semelhantes, ela foi utilizada para verificar os atributos que melhor realizavam a separação das classes.

3) Matriz de covariância: Método estatístico que fornece a correlação existente entre as variáveis, ou seja, quanto maior o valor da covariância entre a variável x e a variável y , mais fortemente correlacionadas estas variáveis estão (Horn & Johnson, 1996). Para os testes, foi utilizada a função COV do Matlab 7.0.

Exemplo da utilização da Matriz de covariância para a seleção dos melhores atributos: suponha que tenhamos 5 atributos a serem analisados: X_1 , X_2 , X_3 , X_4 e X_5 e a matriz de covariância obtida considerando estas 5 variáveis seja dada a seguinte:

$$\begin{pmatrix} 138.32 & -102.12 & -36.20 & -0.94 & -0.14 \\ & 79.74 & 22.38 & 15.3 & 0.11 \\ & & 13.82 & -0.58 & 0.02 \\ & & & 0.64 & 0.03 \\ & & & & 0.26 \end{pmatrix}$$

Então, pode-se observar que cada linha da matriz de covariância mostra como cada variável está relacionada com as demais. Por exemplo, a linha 1, da matriz acima, mostra como a variável X_1 está relacionada com X_2 , X_3 , X_4 e X_5 . Então, se desejamos escolher duas variáveis entre as 5 e optarmos por escolher a variável X_1 , a variável X_5 deveria ser escolhida pois é a que está menos correlacionada com a variável X_1 (pois, $\text{modulo}(\text{cov}(X_1, X_5)) = 0.14$).

7 - RESULTADOS E DISCUSSÕES

Neste trabalho está sendo proposta a classificação de nódulos mamários com base em seu contorno, característica esta de difícil interpretação pelos especialistas, devido à dificuldade de visibilização e baixo contraste das imagens mamográficas.

O detalhamento do contorno e sua interpretação são importantes para a classificação dos nódulos de acordo com o grau de suspeita de malignidade, segundo a padronização BI-RADS (Kopans, 2000). Os resultados aqui apresentados correspondem aos testes feitos em duas fases de experimentos, Tabela 7.1, que tiveram como objetivo classificar nódulos mamários.

Tabela 7.1 - Resumo das duas fases de Experimentos realizados.

Tabela 7.1 - Resumo das duas fases de Experimentos realizados.

Resumo dos Experimentos – Capítulo de Resultados					
1ª. Fase dos Experimentos					
Total de imagens utilizadas	Classificação de 2 classes (Qtd. Imagens por classe)				
RIs	Nódulos		Ausência de Nódulos		
120	60		60		
Objetivo					
Classificar RIs em duas clases de imagens com nódulos e imagens sem nódulos					
14 Atributos utilizados					
Atributos de Textura: Energia ou Uniformidade, Contraste, Correlação, Variância, Momento da diferença inversa, Média da soma, Variância da soma, Entropia da soma, Entropia, Variância da diferença, Entropia da diferença, Medida de informação de correlação 1, Medida de informação de correlação 2 e Máximo coeficiente de correlação.					
2ª. Fase dos Experimentos					
Total de imagens utilizadas	Classificação de 5 classes (Qtd. Imagens por classe)				
RIs	Circunscrita (classe 1)	Obscurecida (classe 2)	Microlobulada (classe 3)	Mal definida (classe 4)	Espiculada (classe 5)
110	22	22	22	22	22
Objetivo					
Classificar RIs em cinco classes de contorno.					
49 Atributos utilizados					
Atributos de Textura: Energia ou Uniformidade, Contraste, Correlação, Variância, Momento da diferença inversa, Média da soma, Variância da soma, Entropia da soma, Entropia, Variância da diferença, Entropia da diferença, Medida de informação de correlação 1, Máximo coeficiente de correlação					
Atributos de Intensidade: Média de intensidade do histograma, Valor de intensidade do maior valor do histograma, Menor intensidade do histograma, Maior intensidade do histograma, Porcentagem do maior valor de intensidade do histograma em relação à escala de 4096 níveis, Diferença da média para o menor valor de intensidade, Diferença da média para o maior valor de intensidade, Porcentagem Maior, Ponto Médio, Ponto mínimo, Porcentagem Total, Variação de intensidade global da RI (que consiste na média da variação de intensidade de todos os <i>pixels</i> da região), Índice de variação de intensidade local (DI - Densidade), Quantidade de <i>pixels</i> com intensidades maiores que a intensidade do pico do histograma, Porcentagem da área da RI com intensidade maior que a intensidade do pico do histograma, Quantidade de níveis de cinza da RI					
Atributos Geométricos: Momentos de Hu1, Hu2, Hu3, Hu4, Hu5, Hu6, Hu7, Momento ₂₀ , Momento ₀₂ , Momento ₁₁ , Momento ₁₂ , Momento ₂₁ , Momento ₃₀ , Momento ₀₃ , Compacidade, Irregularidade, Perímetro da lesão, Área da lesão, Área (pontos brancos) e Raio de Giração.					

7.1 - 1ª Fase dos Experimentos

Para a primeira fase dos experimentos, foram utilizadas 120 regiões de interesse (RIs) de tamanhos variados, selecionadas de acordo com laudos médicos fornecidos junto com as mamografias, sendo 60 imagens contendo nódulos e 60 imagens normais. As Figuras 7.1 e 7.2 mostram exemplos das imagens com nódulos e sem nódulos respectivamente.

Figura 7.1 - Exemplo de RIs com nódulos, utilizadas para os testes iniciais.

Figura 7.2 - Exemplo de RIs normais, utilizadas para os testes iniciais.

Vários testes foram realizados, divididos em experimentos, que serão descritos a seguir. O esquema de classificação completo com as principais etapas desta fase do trabalho pode ser visualizado na Figura 7.3.

Figura 7.3 - Esquema de classificação, utilizado na primeira fase dos experimentos.

7.1.1 - Experimento 1: Extração de todos os Descritores de Textura e Classificação através da Rede Neural SOM para Validação do Algoritmo SOM

Diversos testes foram realizados tendo como objetivo o desenvolvimento de um classificador, baseado em RNA não-supervisionada, que classifique regiões de interesse (RIs) em imagens com nódulos e normais, a princípio. Para este teste foram utilizados exemplos conhecidos para a validação da rede neural SOM, que foi implementada conforme descrito no item 6.2 do capítulo 6.

Nestes testes foram utilizados 14 atributos de textura extraídos das RIs através do procedimento descrito no item 6.1, do capítulo 6, que serviram de entrada para a rede SOM. Foram utilizados os mesmos 120 RIs.

A configuração do Mapa Auto-Organizável de Kohonen que resultou em melhor performance foi: na fase de ordenação, uso de 1000 iterações, com uma taxa de aprendizado $\eta = 0,5$ e raio de vizinhança $r = 5$; e na fase de convergência, também 1000 iterações, porém, com uma taxa de aprendizado $\eta = 0,1$ e raio de vizinhança $r = 1$ em um mapa de 25 por 25 neurônios. Os resultados obtidos pelo algoritmo de classificação apresentaram a formação de dois *clusters*, Figura 7.4, indicando a existência de nódulos,

apresentados no mapa através da cor azul, e a ausência de nódulo, apresentados em verde. Conforme pode ser visualizado na mesma Figura 7.4, mesmo havendo a separação, algumas imagens com nódulo foram classificadas como imagens normais, caracterizando respostas falsas-negativas do classificador.

Figura 7.4 - Clusters do primeiro experimento.

Neste trabalho, utilizando os 14 atributos de textura de Haralick (Haralick *et al.*, 1973; 1979), foi possível obter bons resultados (valores acima de 80%) com número de acerto total nos casos de nódulos suspeitos de 81,66% nos testes com a Rede SOM (Ribeiro *et al.*, 2005a; Ribeiro *et al.*, 2006b; Ribeiro *et al.*, 2006f).

7.1.2 - Experimento 2: Utilização de Gaussianas para a seleção dos Melhores Atributos

Após os testes realizados com todos os atributos de textura, foram geradas 14 curvas de distribuições de gaussianas. Entre estas comparações, algumas não produziram bons resultados, pois muitas áreas das curvas se sobrepõem, como pode ser visto na Figuras 7.5.

Figura 7.5 - Algumas distribuições Gaussianas dos atributos de textura que não produziram bons resultados.

No entanto, seis comparações entre as curvas proporcionaram bons resultados, ou seja, as bases das curvas não se sobrepõem ou possuem pouca sobreposição. Os atributos envolvidos foram: Contraste, Média da Soma, Variância da Soma, Entropia da Soma, Entropia da Diferença e Média de Informação de Correlação 1, conforme apresentado na Figura 7.6. Assim, foram considerados os atributos que melhor representam cada classe e que serviram de entradas a ser utilizadas em um classificador (Ribeiro *et al.*, 2005b; Ribeiro *et al.*, 2006b; Ribeiro *et al.*, 2006f).

a) Contraste.

b) Média da soma.

c) Variância da Soma.

d) Entropia da Soma.

e) Entropia da Diferença

f) Medida de Informação de Correlação 1

Figura 7.6 - Seis distribuições Gaussianas dos atributos de textura que produziram bons resultados.

7.1.3 - Experimento 3: Utilização dos 6 Atributos de Textura selecionados pelas Gaussianas e Classificação através da Rede Neural SOM

Para este experimento foram utilizados os 6 atributos de textura que foram selecionados pelas Gaussianas, conforme descrito no item anterior.

Nestes testes também foram utilizados os mesmos 120 RIs empregados nos experimentos anteriores. A configuração do Mapa Auto-Organizável de Kohonen que resultou em melhor performance foi: na fase de ordenação, 1000 iterações, com uma taxa de aprendizado $\eta = 0,5$ e raio de vizinhança $r = 5$; e na fase de convergência também foram utilizadas 5000 iterações, porém, com uma taxa de aprendizado $\eta = 0,1$ e raio de vizinhança $r = 1$ em um mapa de 25 por 25 neurônios. Os resultados obtidos pelo algoritmo de classificação apresentaram a formação de dois *clusters*, Figura 7.7, com a existência de nódulos apresentada no mapa através da cor azul, e a ausência de nódulo, em verde. Conforme pode ser visualizado na Figura 7.7, mesmo havendo a separação dos nódulos, algumas imagens com nódulo foram classificadas incorretamente.

O classificador obteve 85,83% de taxa de acerto total nos casos de imagens com nódulos. Em comparação com o Experimento 1, foi possível verificar que a seleção dos melhores atributos realmente melhorou a classificação dos padrões em 5,11% (Ribeiro *et al.*, 2005d; Ribeiro *et al.*, 2006b; Ribeiro *et al.*, 2006f).

Figura 7.7 - *Clusters* do Experimento 3.

7.1.4 - Experimento 4: Extração de todos os Descritores de Textura e Classificação através da Rede Neural MLP

Após a realização de testes utilizando a rede não-supervisionada SOM, foram realizados os mesmos testes, agora com um classificador baseado em RNA supervisionada MLP, para classificar regiões de interesse (RIs) em imagens com nódulos e normais.

Os testes realizados com a MLP utilizaram todos os atributos de textura de Haralick, e, entre todos os testes realizados, a melhor configuração encontrada, escolhida experimentalmente, utiliza 26 neurônios na camada escondida, taxa de aprendizagem $\eta = 0,5$ com erro $< 0,09$.

Para a avaliação do algoritmo, foi escolhida uma ferramenta padrão da estatística, conhecida como *cross validation* (Hertz *et al.*, 1991; Haykin, 1994), na qual, o conjunto disponível de dados, com n elementos, é dividido aleatoriamente em um conjunto de treinamento, com 75% do conjunto de dados, e em um conjunto de teste, com 25% do mesmo conjunto de dados. Os exemplos são divididos em 10 partições mutuamente exclusivas, com 75% do conjunto de dados, para treinar o algoritmo. E os 25% de elementos restantes, de cada partição, são utilizados para testar o classificador. Repete-se esse procedimento para todas as partições. A avaliação do grau de generalização do classificador ficará, desta forma, garantida com este método.

Os resultados obtidos pelo algoritmo de classificação, que utilizou um total de 120 RIs divididas em 10 partições com 90 RIs, na fase de treinamento, e 30 RIs na fase de teste, foram validados pela *cross validation*, levaram a 91,44% de acerto na fase de treinamento com um desvio padrão de 3,87 (cujo resultado variou entre 87,57% a 95,31% de acerto) e 86,67% de acerto na fase de testes, com um desvio padrão de 4,58 (variação entre 82,09% a 91,25% de acerto), conforme Tabela 7.2 (Ribeiro *et al.*, 2005c; Ribeiro *et al.*, 2006a; Ribeiro *et al.*, 2006f).

Tabela 7.2 - Resultados da MLP, tendo como entrada todos os atributos de textura.

Treinamento				Teste			
Ciclos*	% de acertos por classe		%Acertos	Ciclos*	% de acertos por classe		%Acertos
	Com Nódulo	Sem Nódulo			Com Nódulo	Sem Nódulo	
6	92,22	100,00	96,11	6	70,00	96,67	83,33
31	78,89	97,78	88,33	31	100,00	76,67	88,33
16	71,11	98,89	85,00	16	96,67	83,33	90,00
12	85,56	97,78	91,67	12	96,67	76,67	86,67
8	93,33	100,00	96,67	8	93,33	60,00	76,67
30	82,22	96,67	89,44	30	100,00	70,00	85,00
10	87,78	97,78	92,78	10	93,33	76,67	85,00
17	92,22	96,67	94,44	17	100,00	80,00	90,00
15	76,67	97,78	87,22	15	90,00	86,67	88,33
30	87,78	97,78	92,78	30	100,00	86,67	93,33
		Média	91,44			Média	86,67
	Desvio Padrão		3,87		Desvio Padrão		4,58

* Número de iterações que o conjunto foi apresentado a rede.

7.1.5 - Experimento 5: Utilização dos 6 Atributos de Textura selecionados pelas Gaussianas e Classificação através da Rede Neural MLP.

Além dos testes realizados com todos os atributos de textura, foram realizados novos testes com os 6 atributos de textura selecionados pelas Gaussianas, que serviram de entrada para a rede MLP. Dentre todos os testes realizados, a melhor configuração encontrada utiliza uma camada intermediária com 32 neurônios, taxa de aprendizagem $\eta = 0,5$ com erro $< 0,09$.

Os resultados obtidos pelo algoritmo de classificação, que utilizou um total de 10 partições com 90 RIs, na fase de treinamento, e 30 RIs na fase de teste, foram validados pela mesma ferramenta estatística *cross validation*, levando a 95,72% de acerto na fase de treinamento com um desvio padrão de 1,17 e 91,50% de acerto na fase de testes, e desvio padrão de 4,41, conforme Tabela 7.3. Com isso foi possível verificar que, através da seleção dos melhores atributos, a rede aumentou seu acerto na fase de treinamento em 4,68% e 5,57% na fase de teste.

Com base nos testes realizados utilizando *cross validation*, Tabela 7.3, foi possível constatar que o pior resultado obtido na fase de treinamento foi 94,44% de acerto com um total de 798 ciclos do algoritmo e o melhor foi 97,78% de acerto com 1008 ciclos. Na fase de teste o pior resultado obtido foi 85% de acerto com um total de 1008 ciclos do algoritmo e o melhor foi 96,67% de acerto com 795 ciclos (Ribeiro *et al.*, 2006f).

Tabela 7.3 - Resultados da MLP, tendo como entrada 6 atributos de textura selecionados pelas Gaussianas.

Treinamento				Teste			
Ciclos *	% de acertos por classe		%Acertos	Ciclos *	% de acertos por classe		%Acertos
	Com Nódulo	Sem Nódulo			Com Nódulo	Sem Nódulo	
798	91,11	97,78	94,44	798	100,00	83,33	91,67
836	93,33	98,89	96,11	836	93,33	96,67	95,00
942	90,00	100,00	95,00	942	83,33	100,00	91,67
959	95,56	98,89	97,22	959	93,33	76,67	85,00
814	91,11	100,00	95,56	814	86,67	100,00	93,33
1008	96,67	98,89	97,78	1008	90,00	80,00	85,00
777	91,11	97,78	94,44	777	100,00	73,33	86,67
836	93,33	98,89	96,11	836	93,33	96,67	95,00
883	93,33	98,89	96,11	883	90,00	100,00	95,00
795	91,11	97,78	94,44	795	100,00	93,33	96,67
		Média	95,72			Média	91,50
	Desvio Padrão		1,17		Desvio Padrão		4,41

* Número de iterações que o conjunto foi apresentado a rede.

7.1.6 - Conclusões

Com base nas comparações, foi possível observar que a seleção dos atributos que melhor representam cada classe irá realmente melhorar a performance do classificador e, com isso, aumentar sua precisão. Nas comparações realizadas entre as duas redes neurais, foi possível observar que, por exemplo, no caso da Rede Neural MLP, antes da seleção dos melhores atributos de textura, o classificador estava registrando 91,44% de acerto na fase de treinamento e 86,67% na fase de testes; mas, após a seleção das melhores características, aumentou seu acerto na fase de treinamento e de testes em 4,68% e 5,57%, respectivamente. Já com a Rede Neural SOM, antes da seleção dos melhores atributos de textura, a variação do nível de acertos foi de mais 5,11% (de 81,66% para 85,83%). Embora os resultados com a MLP tenham sido melhores, este trabalho não enfoca a classificação de apenas duas classes de padrões previamente conhecidos, e sim a separação de vários padrões em 5 classes conforme será discutido na 2ª Fase de Experimentos.

7.2 - 2ª Fase dos Experimentos

Os mamogramas utilizados nesta nova fase foram obtidos do Hospital das Clínicas de Botucatu (UNESP) e do Hospital das Clínicas de Ribeirão Preto (FMRP/USP), e as RIs foram identificadas por um especialista. Todas as imagens selecionadas foram laudadas com base na caracterização dos cinco tipos de contornos de nódulos, segundo a padronização BI-RADS, conforme Tabela 7.4 e Tabela 7.5.

Tabela 7.4 - Levantamento de imagens laudadas por contorno (HC - UNESP/Botucatu).

Contornos segundo Kopans (Kopans, 2000)	Qtd.	Nomes dos contornos descritos nos laudos
Circunscrito	13	Bem Definido
Obscurecido	16	Parcialmente Definido
Microlobular	29	Bocelado
Mal Definido	13	Mal Definido
Espicular	24	Espiculado
Total	95	Imagens

Tabela 7.5 - Levantamento de imagens laudadas por contorno (HC - FMRP/USP).

Contornos segundo Kopans (Kopans, 2000)	Qtd.	Nomes dos contornos descritos nos laudos
Circunscrito	18	Bem Definido
Obscurecido	9	Parcialmente Definido
Microlobular	----	Bocelado
Mal Definido	9	Mal Definido
Espicular	4	Espiculado
Total	40	Imagens

Com base nas Tabelas 7.4 e 7.5 foi possível verificar que a classe 4 (Mal Definido) estava associado a 22 imagens. Por isso, resolveu-se utilizar a mesma quantidade de padrões para cada uma das classes. Assim, 135 regiões de interesse (RIs) selecionadas, foi considerado um conjunto de imagens com 110 RIs de tamanhos variados, com uma reserva de 25 RIs para serem utilizadas posteriormente. As imagens das 110 RIs são formadas por 22 imagens correspondente a cada uma das cinco classes estudadas: circunscrita (classe 1), obscurecida (classe 2), microlobulada (classe 3), mal definida (classe 4) e espiculada (classe 5). Exemplos dessas classes podem ser visualizados através da Figura 7.8.

Figura 7.8 - Exemplo de RIs utilizadas para os testes, representando cada uma das 5 classes de contorno.

Neste segundo experimentos foram realizados diversos treinamentos com várias combinações de classe dando um total aproximado de 3000 treinamentos. Para realizar esses testes, foram utilizados 46 computadores com as seguintes configurações: 10 computadores Pentium 4, 3.0 Mhz, 512 de memória e HD 80Gb; 18 computadores Atlons, 1.8 Mhz, 512 de memória, HD 80 Gb; 18 computadores Duron, 900 Mhz, 128 memória e HD 40Gb.

7.2.1 - Experimento 1: Extração de todos os Descritores e Classificação através das Redes Neurais MLP e SOM

Com base nas imagens das 110 RIs, foram extraídos atributos de textura, intensidade e geométricos, num total de 49 atributos:

- Descritores de textura: Energia ou Uniformidade, Contraste, Correlação, Variância, Momento da diferença inversa, Média da soma, Variância da soma, Entropia da soma, Entropia, Variância da diferença, Entropia da diferença, Medida de informação de correlação 1 e Máximo coeficiente de correlação (Haralick et al., 1973).

- **Descritores de Intensidade:** Média de intensidade do histograma, Valor de intensidade do maior valor do histograma, Menor intensidade do histograma, Maior intensidade do histograma, Porcentagem do maior valor de intensidade do histograma em relação à escala de 4096 níveis, Porcentagem Maior, Ponto Médio, Ponto Mínimo, Porcentagem Total, Diferença da média para o menor valor de intensidade, Diferença da média para o maior valor de intensidade, Variação de intensidade global da RI (que consiste na média da variação de intensidade de todos os *pixels* da região), Índice de variação de intensidade local (DI - Densidade Integrada - que integra as diferenças das variações locais de intensidades e a variação média, dando uma medida que quantifica contraste entre as partes mais claras da imagem e o restante), Quantidade de *pixels* com intensidades maiores que a intensidade do pico do histograma, Porcentagem da área da RI com intensidade maior que a intensidade do pico do histograma e Quantidade de níveis de cinza da RI (Wang, 1999; Patrocínio, 2004).

- **Descritores Geométricos:** foram extraídos das RIs segmentadas através do esquema de processamento para detecção de nódulos desenvolvido previamente (Santos *et al.*, 2002); com base nessas RIs segmentadas foram extraídos: Momentos, Momentos Invariantes (MI) de Hu, perímetro, área, compacidade e irregularidade (Patrocínio, 2004b).

Esses 49 atributos serviram de entrada para as Redes Neurais MLP e SOM. Vários treinamentos, num total de 532, foram realizados com diversas topologias, sendo selecionados os melhores resultados dos treinamentos conforme Tabela 7.6, com as topologias informadas nas Tabelas 7.7 e 7.8. Várias topologias foram testadas para a Rede SOM, utilizando 200, 500, 1000 e 2000 iterações, mas, na maioria dos treinamentos, as topologias com 1000 iterações apresentaram maior acerto.

Na Tabela 7.6, estão apresentadas as combinações de classes treinadas, sendo que as classes 1 e 2 foram consideradas como benignas, e as classes 3, 4 e 5 como malignas, Figura 2.7. As porcentagens de Verdadeiro Positivo (VP), Falso Negativo (FN), Falso Positivo (FP), Verdadeiro Negativo (VN) e o valor de Az obtido a partir do cálculo da área sob a curva ROC (*Receiver Operating Characteristic*) (Metz, 1986) correspondente também são mostrados naquela tabela. Deve-se recordar que quanto mais o valor da área sob a curva (Az) se aproximar da unidade, melhor será o comportamento do sistema sob análise. Isso significa que o sistema avaliado tem grande percentual de acertos com um baixo índice de falsas detecções, sendo um sistema de alta sensibilidade, que é uma situação sempre desejável.

O índice Falso Negativo também é muito importante para a avaliação dos resultados, pois não basta apenas um Az próximo de 1,0, mas é necessário também um baixo FN, que é a taxa relacionada aos casos em que, apesar de presente, o sinal buscado – um tumor, por exemplo – não foi detectado.

Tabela 7.6 - Treinamentos realizados com todos os atributos.

Classes		MLP					SOM				
		% nódulos por contorno				Az	% nódulos por contorno				Az
Benignas	Malignas	VP	FN	FP	VN		VP	FN	FP	VN	
1, 2,	3,4 e 5	79	21	39	61	0,75	62	38	48	52	0,59
1, 2,	4 e 5	77	23	70	30	0,56	55	45	45	55	0,52
1,	3 e 5	84	16	50	50	0,74	57	43	41	59	0,61
1	e 5	77	23	23	77	0,84	55	45	14	86	0,83

Tabela 7.7 - Topologias utilizadas pela Rede Neural MLP.

Classes	MLP					
	Entrada	Camada Escondida 1	Camada Escondida 2	Saída	Tx. de Aprendizagem	Erro <
1,2,3,4 e 5	49	80	49	5	0,9	0,01
1,2,4 e 5	49	70	35	4	0,9	0,05
1,3 e 5	49	70	30	3	0,9	0,01
1 e 5	49	64	32	2	0,9	0,01

Tabela 7.8 - Topologias utilizadas pela Rede Neural SOM.

Classes	SOM					
	Ordenação			Convergência		
	Iteração	Raio de Vizinhança	Tx. de aprendizagem	Iteração	Raio de vizinhança	Tx. de aprendizagem
1,2,3,4 e 5	1000	5	0,1	1000	1	0,01
1,2,4 e 5	2000	5	0,1	2000	1	0,01
1,3 e 5	1000	5	0,1	1000	1	0,01
1 e 5	1000	5	0,1	1000	1	0,01

Conforme apresentado na Tabela 7.6, os melhores valores de Az e FN foram obtidos com a Rede Neural MLP. Das diversas combinações de classe, os melhores resultados foram com os treinamentos utilizando 5 saídas, ou seja, para classificação em 5 classes, obtendo Az igual a 0,75 e FN 21%, com as classes 1, 3 e 5, obtendo Az igual a 0,74 e FN 16% e com as classes 1 e 5 obtendo Az igual a 0,84. O resultado da Rede Neural

SOM para as classes 1 e 5 mostrou Az igual a 0,83, porém, o FN foi muito alto (45%). Os treinamentos foram validados através da técnica *leaving-one-out* sendo considerado 22 RIs para cada classes, ou seja, 110 RIs para as classes 1, 2, 3, 4 e 5, 88 RIs para as Classes 1, 2, 4 e 5, 66 RIs para as classes 1, 3 e 5 e 44 RIs para as classes 1 e 5. Através do resultado desses treinamentos foram calculados os VP, FN, FP, VN para cada conjunto de classes e foram geradas curvas ROC dos resultados obtidos e através delas foram calculados os valores de Az (Ribeiro *et al*, 2006g).

Os resultados obtidos através do método de validação, produziram os índices de VP, FN, FP, VN. A partir das taxas de verdadeiro positivo (VP), que corresponde à proporção de casos de lesões corretamente identificados, e de falso positivo (FP), que é um erro de diagnóstico que pode levar um paciente a ser tratado de uma doença que ele não tem, foram geradas curvas ROC para o resultado de cada treinamento, conforme dados já mostrados na Tabela 7.6.

As curvas foram construídas através do programa *Microcal Origin 6.0*. As curvas ROC da Rede MLP podem ser visualizadas nas Figuras 7.9. As curvas ROC da Rede SOM podem ser visualizadas nas Figuras 7.10.

a) Classes 1,2,3,4 e 5 - Az = 0,75.

b) Classes 1,2,4 e 5 - Az = 0,56.

c) Classes 1,3 e 5 - $Az = 0,74$. d) Classes 1 e 5 - $Az = 0,84$.

Figura 7.9 - Curvas ROC dos resultados dos treinamentos realizados com a Rede MLP (Tabela 7.6).

a) Classes 1,2,3,4 e 5 - $Az = 0,59$. b) Classes 1,2,4 e 5 - $Az = 0,52$. c) Classes 1,3 e 5 - $Az = 0,61$. d) Classes 1 e 5 - $Az = 0,83$.

Figura 7.10 - Curvas ROC dos resultados dos treinamentos realizados com a Rede SOM (Tabela 7.6).

7.2.2 - Experimento 2: Utilização da Rede Neural SOM e Gaussianas para a seleção dos Melhores Atributos

Para a seleção dos melhores atributos, os que melhor caracterizam os cinco contornos, foi utilizada uma rede neural não supervisionada do tipo *Self-Organizing Map* (SOM) para distribuir os atributos extraídos das 110 imagens nas classes, juntamente com análise de curvas gaussianas, para mostrar a distribuição de cada atributo extraído das imagens para cada uma das classes. Ou seja, para cada atributo presente nas 110 imagens foi gerada uma rede SOM e foi observado como as imagens de cada classe foram agrupadas. Para validar esta separação em classes, foi utilizada uma análise através de distribuição gaussiana, onde se repetiu o mesmo procedimento anterior. Foram selecionados, com base nestas análises, os atributos que melhor caracterizavam cada classe indicado por ambas as técnicas. Os atributos que foram indicados pela distribuição gaussiana, mas não indicados pela Rede SOM não foram considerados como relevantes. A partir daí, foi possível observar o quanto um atributo é significativo para representar cada classe, através da observação da sobreposição das curvas gaussianas e na conferência da separação de classes através da SOM.

Foram realizadas duas separações, uma tendo como base as cinco classes e outra apenas com as classes 1, 3 e 5, porque as classes 2 e 4 são, de certa forma, parecidas e acabam causando uma certa dificuldade na separação de classes. Os resultados dessas seleções são apresentados a seguir:

a) Seleção utilizando as cinco classes de contorno: Como está sendo utilizado um total de 49 atributos extraídos de 110 imagens, foram geradas 49 SOMs com a seguinte topologia: na fase de ordenação, 1000 iterações, com uma taxa de aprendizado $\eta = 0,1$ e raio de vizinhança $r = 5$; e na fase de convergência também foram utilizadas 1000 iterações, porém, com uma taxa de aprendizado $\eta = 0,01$ e raio de vizinhança $r = 1$ em um mapa de 100 por 100 neurônios, e 49 gaussianas. Com base nos resultados da Rede SOM e da validação através de distribuições gaussianas, conforme exemplificado no item 6.4, foram verificadas as possíveis combinações de classes. Após as comparações foram selecionados 20 atributos (Ribeiro *et al.*, 2006g):

- Atributos de textura: Contraste, Entropia da Diferença, Entropia da Soma, Momentos da Diferença Inversa, Média da Soma e Variância;

- Atributos de Intensidade: quantidade de níveis de cinza da RI, índice de variação de intensidade local (DI - Densidade Integrada), diferença da média para o menor valor de intensidade, diferença da média para o maior valor de intensidade e variação de intensidade global da RI (que consiste na média da variação de intensidade de todos os *pixels* da região);
- Descritores Geométricos: Momentos de Hu1, Momentos de Hu4, Momento₂₀, Compacidade, Irregularidade, Perímetro da lesão, Área da lesão, Área (pontos brancos) e Raio de Giração.

Como exemplo, está sendo apresentado nas Figuras de 7.11 a 7.16 os atributos de textura selecionados:

Figura 7.11 - Mapa da rede SOM e distribuição gaussiana - Atributo de textura: Contraste.

Figura 7.12 - Mapa da rede SOM e distribuição gaussiana - Atributo de textura: Entropia da Diferença.

Figura 7.13 - Mapa da rede SOM e distribuição gaussiana - Atributo de textura: Entropia da Soma.

Figura 7.14 - Mapa da rede SOM e distribuição gaussiana - Atributo de textura: Momento da Diferença Inversa.

Figura 7.15 - Mapa da rede SOM e distribuição gaussiana - Atributo de textura: Média da Soma.

Figura 7.16 - Mapa da rede SOM e distribuição gaussiana - Atributo de textura: Variância.

b) Seleção utilizando como base as classes 1, 3 e 5: Novamente estarão sendo utilizados os 49 atributos porém, agora extraídos de 66 imagens, pois estamos trabalhando com três classes. Foram geradas 49 SOMs, com a mesma topologia da seleção anterior, e 49 gaussianas. Com base nos resultados da Rede SOM e da validação através das distribuições gaussianas, foram verificadas as possíveis combinações de classes. Após as comparações, foram selecionados 7 atributos, como exemplo, esta sendo apresentando nas Figuras de 7.17 a 7.19 os atributos de textura que foram selecionados:

- Atributos de textura: Entropia da Diferença, Entropia da Soma e Variância;
- Atributos de Intensidade: quantidade de níveis de cinza da RI;
- Descritores Geométricos: Perímetro da lesão, Área da lesão e Área (pontos brancos);

Figura 7.17 - Mapa da rede SOM e distribuição gaussiana - Atributo de textura: Entropia da Diferença.

Figura 7.18 - Mapa da rede SOM e distribuição gaussiana - Atributo de textura: Entropia da Soma.

Figura 7.19 - Mapa da rede SOM e distribuição gaussiana - Atributo de textura: Variância.

7.2.3 - Experimento 3: Utilização dos atributos selecionados por SOM e Gaussianas como entrada para as Redes Neurais MLP e SOM

Após a seleção dos melhores atributos, através da Rede Neural SOM e Distribuições Gaussianas, eles foram utilizados como entrada para as Redes Neurais MLP e SOM. Os resultados obtidos com o treinamento das redes foram os seguintes:

a) Utilizando os 20 atributos selecionados pela rede neural SOM e Gaussianas:

Vários treinamentos, num total de 715, foram realizados utilizando os 20 atributos selecionados como entrada para as Redes Neurais MLP e SOM. Diversas topologias, foram utilizadas e apenas os melhores resultados foram selecionados, conforme Tabela 7.9, com as respectivas topologias informadas nas Tabelas 7.10 e 7.11. Várias topologias foram testadas para a Rede SOM, utilizando 200, 500, 1000 e 2000 iterações, mas na maioria dos treinamentos as topologias com 1000 iterações apresentaram maior acerto. Os treinamentos foram validados através da técnica *leaving-one-out*, como na Experimento 1, e foram geradas curvas ROC dos resultados obtidos através do método de validação. Conforme pode ser visualizado na Tabela 7.9, novamente os melhores valores de Az e FN foram obtidos com a Rede Neural MLP. Das diversas combinações de classe, os melhores resultados de treinamento foram com as cinco classes, registrando Az de 0,80 e FN de 18%, e com as classes 1 e 5 apenas sendo obtido Az igual a 0,88. Os melhores resultados com a Rede Neural SOM foram com as classes 1, 3 e 5 (Az= 0,84 com FN = 25%) e para classes 1 e 5 (Az= 0,83 com FN = 27%), mesmo havendo redução do FN quando comparado com a taxa de FN obtida com as 49 entradas, tal índice ainda foi alto (Ribeiro *et al*, 2006g).

Tabela 7.9 - Treinamentos realizados com 20 atributos selecionados pela Rede Neural SOM e Gaussianas.

Classes		MLP					SOM				
		% nódulos por contorno					% nódulos por contorno				
Benignas	Malignas	VP	FN	FP	VN	Az	VP	FN	FP	VN	Az
1, 2,	3, 4 e 5	82	18	39	61	0,80	71	29	57	43	0,60
1, 2,	4 e 5	66	34	36	64	0,70	55	45	57	43	0,50
1,	3 e 5	86	14	59	41	0,71	75	25	23	77	0,84
1	e 5	86	14	23	77	0,88	73	27	23	77	0,83

Tabela 7.10 - Topologias utilizadas pela Rede Neural MLP.

Classes	MLP					
	Entrada	Camada Escondida 1	Camada Escondida 2	Saída	Tx. de Aprendizagem	Erro <
1,2,3,4 e 5	20	40	20	5	0,9	0,01
1,2,4 e 5	20	40	20	4	0,9	0,01
1,3 e 5	20	28	14	3	0,9	0,01
1 e 5	20	32	12	2	0,9	0,01

Tabela 7.11 - Topologias utilizadas pela Rede Neural SOM.

Classes	SOM					
	Ordenação			Convergência		
	Iteração	Raio de vizinhança	Tx. de aprendizagem	Iteração	Raio de vizinhança	Tx. de aprendizagem
1,2,3,4 e 5	1000	5	0,1	1000	1	0,01
1,2,4 e 5	1000	5	0,1	1000	1	0,01
1,3 e 5	1000	5	0,1	1000	1	0,01
1 e 5	1000	5	0,1	1000	1	0,01

As curvas ROC obtidas nos resultados da Rede MLP podem ser visualizadas na Figura 7.20. As curvas ROC da Rede SOM podem ser visualizadas na Figura 7.21.

a) Classes 1,2,3,4 e 5 - Az = 0,80.

b) Classes 1,2,4 e 5 - Az = 0,70.

c) Classes 1,3 e 5 - $Az = 0,71$. d) Classes 1 e 5 - $Az = 0,88$.

Figura 7.20 - Curvas ROC dos resultados dos treinamentos realizados com a Rede MLP (Tabela 7.9).

a) Classes 1,2,3,4 e 5 - $Az = 0,60$. b) Classes 1,2,4 e 5 - $Az = 0,50$. c) Classes 1,3 e 5 - $Az = 0,84$. d) Classes 1 e 5 - $Az = 0,83$.

Figura 7.21 - Curvas ROC dos resultados dos treinamentos realizados com a Rede SOM (Tabela 7.9).

b) Utilizando os sete atributos selecionados pela Rede Neural SOM e Gaussianas:

novos treinamentos, um total de 694, foram realizados utilizando os sete atributos selecionado como entrada para as Redes Neurais MLP e SOM. Diversas topologias, foram utilizadas e apenas os melhores resultados foram selecionados conforme Tabela 7.12, com as topologias informadas nas Tabelas 7.13 e 7.14 Os treinamentos foram validados através da técnica *leaving-one-out* e foram geradas curvas ROC dos resultados obtidos através do método de validação. Conforme pode ser visualizado na Tabela 7.12, novamente os melhores valores de Az e FN foram obtidos com a Rede Neural MLP. Das diversas combinações de classe os melhores resultados de treinamentos foram com as classes 1,3 e 5, (Az = 0,88 e FN = 11%) e com as classes 1 e 5 (Az = 0,90 e FN = 23%). Os melhores resultados com a Rede Neural SOM foram com as classes 1, 3 e 5 (Az = 0,68 com FN = 14%).

Tabela 7.12 - Treinamentos realizados com sete atributos selecionados pela Rede Neural SOM e Gaussianas.

Classes		MLP					SOM				
		% nódulos por contorno				Az	% nódulos por contorno				Az
Benignas	Malignas	VP	FN	FP	VN		VP	FN	FP	VN	
1, 2,	3, 4 e 5	73	27	41	59	0,71	55	45	68	32	0,47
1, 2,	4 e 5	66	34	48	52	0,62	55	45	57	43	0,50
1,	3 e 5	89	11	27	73	0,88	86	14	64	36	0,68
1	e 5	77	23	14	77	0,90	64	36	36	64	0,69

Tabela 7.13 - Topologias utilizadas pela Rede Neural MLP.

Classes	MLP					
	Entrada	Camada Escondida 1	Camada Escondida 2	Saída	Tx. de Aprendizagem	Erro <
1,2,3,4 e 5	7	48	24	5	0,9	0,01
1,2,4 e 5	7	40	20	4	0,9	0,01
1,3 e 5	7	20	12	3	0,9	0,01
1 e 5	7	20	12	2	0,9	0,01

Tabela 7.14 - Topologias utilizadas pela Rede Neural SOM.

Classes	SOM					
	Ordenação			Convergência		
	Iteração	Raio de vizinhança	Tx. de aprendizagem	Iteração	Raio de vizinhança	Tx. de aprendizagem
1,2,3,4 e 5	1000	5	0,1	1000	1	0,01
1,2,4 e 5	1000	5	0,1	1000	1	0,01
1,3 e 5	1000	5	0,1	1000	1	0,01
1 e 5	1000	5	0,1	1000	1	0,01

As curvas ROC obtidas nos resultados da Rede MLP podem ser visualizadas na Figura 7.22. As curvas ROC da Rede SOM podem ser visualizadas na Figura 7.23.

a) Classes 1,2,3,4 e 5 - $Az = 0,71$. b) Classes 1,2,4 e 5 - $Az = 0,62$. c) Classes 1,3 e 5 - $Az = 0,88$. d) Classes 1 e 5 - $Az = 0,90$.

Figura 7.22 - Curvas ROC dos resultados dos treinamentos realizados com a Rede MLP (Tabela 7.12).

a) Classes 1,2,3,4 e 5 - $Az=0,47$. b) Classes 1,2,4 e 5 - $Az = 0,50$. c) Classes 1,3 e 5 - $Az = 0,68$. d) Classes 1 e 5 - $Az = 0,69$.

Figura 7.23 - Curvas ROC dos resultados dos treinamentos realizados com a Rede SOM (Tabela 7.12).

7.2.4 - Experimento 4: Utilização de matriz de covariância para a seleção de atributos

Além da seleção realizada através da Rede Neural SOM e das Gaussianas, foi utilizado um método estatístico para uma nova seleção de atributos através da Matriz de Covariância. Foram selecionados aleatoriamente os atributos Uniformidade e Contraste para serem utilizados como base para a conferência da correlação existente entre estes atributos e o restante. Ou seja, com base na correlação existente entre os atributos, foram selecionados os com menor valores de covariância entre, por exemplo, o atributo Uniformidade e os outros 48 atributos, pois, quanto menor a covariância entre eles, melhor esse atributo irá caracterizar a separação das classes. Os itens abaixo mostram os atributos que foram selecionados:

- a) Com base na Uniformidade, foram selecionados 21 atributos sendo eles: Uniformidade, Correlação, Média de intensidade do histograma, Diferença da média para o maior valor de intensidade, Quantidade de níveis de cinza da RI, Porcentagem Maior, Ponto Médio, Porcentagem Total, Momentos de Hu2, Hu5, Hu6, Hu7, Momentos₂₀, Momentos₁₁, Momentos₀₂, Momentos₃₀, Momentos₂₁, Momentos₁₂, Momentos₀₃, Irregularidade e Raio de Giração.
- b) Com base no Contraste, foram selecionados 9 atributos sendo eles: Contraste, Medida de informação de correlação 1, Máximo coeficiente de correlação, Média de intensidade do histograma, Diferença da média para o maior valor de intensidade, Quantidade de níveis de cinza da RI, Porcentagem Maior, Irregularidade e Raio de Giração.

7.2.5 - Experimento 5: Utilização dos atributos selecionados pela Matriz de Covariância como entrada para as Redes Neurais MLP e SOM

Após a seleção dos melhores atributos, através da Matriz de Covariância, eles foram utilizados como entrada para as Redes Neurais MLP e SOM. Os treinamentos foram validados através da técnica *leaving-one-out* e foram geradas curvas ROC dos resultados obtidos através do método de validação. Os resultados obtidos com o treinamento das redes foram:

a) Utilizando os 21 atributos selecionados pela Matriz de Covariância: vários treinamentos, num total de 312, foram realizados utilizando os 21 atributos selecionados como entrada para as Redes Neurais MLP e SOM. Diversas topologias foram utilizadas, e apenas os melhores resultados foram selecionados conforme Tabela 7.15, com as topologias informadas nas Tabelas 7.16 e 7.17, em que, novamente os melhores resultados de Az e FN foram obtidos com a Rede Neural MLP. Das diversas combinações de classe, os melhores resultados de treinamento foram com as cinco classes, (Az = 0,71 e FN alto = 33%) e com as classes 1 e 5 (Az = 0,77 e FN alto = 27%). A Rede Neural SOM para estes testes não produziu bons resultados, no máximo um Az = 0,57 e FN muito alto de 45%.

Tabela 7.15 - Treinamentos realizados com 21 atributos selecionados pela Matriz de Covariância.

Classes		MLP					SOM				
		% nódulos por contorno				Az	% nódulos por contorno				Az
Benignas	Malignas	VP	FN	FP	VN		VP	FN	FP	VN	
1, 2,	3, 4 e 5	67	33	34	66	0,71	47	53	77	23	0,43
1, 2,	4 e 5	66	34	36	64	0,70	27	73	66	34	0,41
1,	3 e 5	73	27	68	32	0,54	52	48	45	55	0,55
1	e 5	73	27	32	68	0,77	55	45	45	55	0,57

Tabela 7.16 - Topologias utilizadas pela Rede Neural MLP.

Classes	MLP					
	Entrada	Camada Escondida 1	Camada Escondida 2	Saída	Tx. de Aprendizagem	Erro <
1,2,3,4 e 5	21	40	20	5	0,9	0,01
1,2,4 e 5	21	48	24	4	0,9	0,01
1,3 e 5	21	48	24	3	0,9	0,01
1 e 5	21	40	20	2	0,9	0,01

Tabela 7.17 - Topologias utilizadas pela Rede Neural SOM.

Classes	SOM					
	Ordenação			Convergência		
	Iteração	Raio de vizinhança	Tx. de aprendizagem	Iteração	Raio de vizinhança	Tx. de aprendizagem
1,2,3,4 e 5	1000	5	0,1	1000	1	0,01
1,2,4 e 5	1000	5	0,1	1000	1	0,01
1,3 e 5	1000	5	0,1	1000	1	0,01
1 e 5	1000	5	0,1	1000	1	0,01

As curvas ROC obtidas nos resultados da Rede MLP podem ser visualizadas na Figura 7.24. As curvas ROC da Rede SOM podem ser visualizadas na Figura 7.25.

a) Classes 1,2,3,4 e 5 - $Az = 0,71$. b) Classes 1,2,4 e 5 - $Az = 0,70$. c) Classes 1,3 e 5 - $Az = 0,54$. d) Classes 1 e 5 - $Az = 0,77$.

Figura 7.24 - Curvas ROC dos resultados dos treinamentos realizados com a Rede MLP (Tabela 7.15).

a) Classes 1,2,3,4 e 5 - $Az = 0,43$. b) Classes 1,2,4 e 5 - $Az = 0,41$.

c) Classes 1,3 e 5 - $Az = 0,55$.d) Classes 1 e 5 - $Az = 0,57$.

Figura 7.25 - Curvas ROC dos resultados dos treinamentos realizados com a Rede SOM (Tabela 7.15).

b) Utilizando os 9 atributos selecionados pela Matriz de Covariância: Nestes testes novamente foram realizados diversos treinamentos, num total de 312, tendo como entrada para as Redes Neurais MLP e SOM os 9 atributos selecionados pela Matriz de Covariância. Os melhores resultados foram selecionados conforme Tabela 7.18, com as topologias informadas nas Tabelas 7.19 e 7.20, onde mais uma vez os melhores valores de Az foram obtidos pela Rede Neural MLP. Das diversas combinações de classe, os melhores resultados de treinamento foram com as classes 1,2,4 e 5, ($Az = 0,77$ e FN alto = 39%) e com as classes 1, 3 e 5 ($Az = 0,74$ e FN = 11%). A Rede Neural SOM para este teste novamente não obteve bons resultados, obtendo um Az máximo de 0,59 e FN muito alto (45%).

Tabela 7.18 - Treinamentos realizados com 9 atributos selecionados pela Matriz de Covariância.

Classes		MLP					SOM				
		% nódulos por contorno				Az	% nódulos por contorno				Az
Benignas	Malignas	VP	FN	FP	VN		VP	FN	FP	VN	
1, 2, 3, 4 e 5		70	30	41	59	0,69	50	50	89	11	0,40
1, 2, 4 e 5		61	39	23	77	0,77	45	55	73	27	0,43
1, 3 e 5		89	11	59	41	0,74	30	70	50	50	0,46
1 e 5		73	27	23	77	0,83	55	45	41	59	0,59

Tabela 7.19 - Topologias utilizadas pela Rede Neural MLP.

Classes	MLP					
	Entrada	Camada Escondida 1	Camada Escondida 2	Saída	Tx. de Aprendizagem	Erro <
1,2,3,4 e 5	9	25	15	5	0,9	0,01
1,2,4 e 5	9	25	15	4	0,9	0,01
1,3 e 5	9	20	12	3	0,9	0,01
1 e 5	9	20	12	2	0,7	0,01

Tabela 7.20 - Topologias utilizadas pela Rede Neural SOM.

Classes	SOM					
	Ordenação			Convergência		
	Iteração	Raio de vizinhança	Tx. de aprendizagem	Iteração	Raio de vizinhança	Tx. de aprendizagem
1,2,3,4 e 5	1000	5	0,1	1000	1	0,01
1,2,4 e 5	1000	5	0,1	1000	1	0,01
1,3 e 5	1000	5	0,1	1000	1	0,01
1 e 5	1000	5	0,1	1000	1	0,01

As curvas ROC obtidas nos resultados da Rede MLP podem ser visualizadas na Figura 7.26. As curvas ROC da Rede SOM podem ser visualizadas na Figura 7.27.

a) Classes 1,2,3,4 e 5 - Az = 0,69.

b) Classes 1,2,4 e 5 - Az = 0,77.

c) Classes 1,3 e 5 - $Az = 0,74$. d) Classes 1 e 5 - $Az = 0,83$.

Figura 7.26 - Curvas ROC dos resultados dos treinamentos realizados com a Rede MLP (Tabela 7.18).

a) Classes 1,2,3,4 e 5 - $Az = 0,40$. b) Classes 1,2,4 e 5 - $Az = 0,43$. c) Classes 1,3 e 5 - $Az = 0,46$. d) Classes 1 e 5 - $Az = 0,59$.

Figura 7.27 - Curvas ROC dos resultados dos treinamentos realizados com a Rede SOM (Tabela 7.18).

7.2.6 - Experimento 6: Classificador Final

Em todos os diversos testes realizados nos experimentos anteriores, verificou-se que os melhores resultados foram obtidos através da seleção dos atributos realizada pela Rede Neural SOM e Gaussianas, enquanto que a Rede Neural que produziu os melhores resultados na fase de classificação foi a Rede MLP. Com base nestas conclusões foram selecionados os treinamentos com maior Az e menor FN, conforme pode ser verificado na Tabela 7.21 e a topologia da rede pode ser verificada na Tabela 7.22 (Ribeiro *et al.*, 2006c).

Tabela 7.21 - Melhores resultados de todos os treinamentos.

Classes		MLP				
		% nódulos por contorno				Az
Benignas	Malignas	VP	FN	FP	VN	
1, 2,	3, 4 e 5	82	18	39	61	0,80
1,	3 e 5	89	11	27	73	0,88
1	e 5	77	23	14	77	0,90

Tabela 7.22 - Topologias dos melhores resultados de todos os treinamentos.

Classes		MLP					
		Topologia da rede					
Benignas	Malignas	Entrada	Camada Esc. 1	Camada Esc. 2	Saída	Tx. de Aprendizagem	Erro <
1, 2,	3, 4 e 5	20	40	20	5	0,9	0,01
1,	3 e 5	7	20	12	3	0,9	0,01
1	e 5	7	20	12	2	0,9	0,01

Para as classes 1, 2, 3, 4 e 5 foram realizados 110 treinamentos, para as classes 1, 3 e 5 foram realizados 66 treinamentos e para as classes 1 e 5 foram realizados 44 treinamentos, pois havia 22 RIs de cada classe para ser treinadas. Destes treinamentos foi selecionado um, de cada conjunto de classes, para que os pesos pudessem ser fixados. Após a fixação dos pesos, foram realizados novos testes, agora tendo como entradas as 110 RIs para todos os conjuntos de classes.

Os testes com as classes 1,3 e 5 e classes 1 e 5, com as 110 imagens, tiveram que ser avaliados de forma diferente, já que existiam imagens de outras classes associadas ao conjunto. Por isso, tais testes ocorreram da seguinte forma:

- Para as classes 1,3 e 5: foi considerado que as imagens pertencentes à classe 2 – que é uma classe benigna e possui semelhança com a classe 1 – quando apresentadas ao classificador, deveriam ser classificadas como classe 1; ou seja, passou-se a ter 44 RIs a serem classificadas nessa categoria ao invés de 22 RIs; a classe 3 se manteve com o mesmo número de imagens do treinamento (22 RIs); já as imagens pertencentes à classe 4 – que é uma classe associada a casos malignos e possui semelhanças com a classe 5 – quando apresentadas ao classificador, deveriam ser consideradas como classe 5 (que passou a ter também 44 RIs).
- Para as classes 1 e 5: foi considerado que as imagens pertencentes às classes 1 e 2 deveriam ser classificadas como classe 1, e as pertencentes às classes 3, 4 e 5 deveriam ser todas classificadas como classe 5.

Os resultados dos testes com o classificador final, conforme pode ser visualizado na Tabela 7.23 e Tabela 7.24, foram bastante satisfatórios, sendo o melhor deles o obtido pela análise de cinco classes com 99% de acerto e Az igual 0,99. O pior resultado foi obtido pelo conjunto de separação em classes 1, 3 e 5, pois, como dentro do conjunto de imagens existia a classe 4, que deveria ser classificada como classe 5 e possui semelhanças com a classe 2, as imagens correspondentes foram classificadas na sua maioria como classe 1, Figura 2.7.

Tabela 7.23 - Testes percentuais realizados com o Classificador Final, utilizando 110 imagens.

Classes	MLP					
	% de Acertos por Classe					% Média de Acerto
	1	2	3	4	5	
1,2,3,4 e 5	100	100	100	95	100	99
1,3 e 5	82	--	50	--	36	57
1 e 5	91	--	--	--	62	74

Tabela 7.24 - Testes realizados com o Classificador Final, utilizando 110 imagens.

Classes		MLP				
		% nódulos por contorno				Az
Benignas	Malignas	VP	FN	FP	VN	
1, 2,	3, 4 e 5	100	0	2	98	0,99
1,	3 e 5	39	61	18	82	0,69
1	e 5	62	38	9	91	0,91

As curvas ROC referentes ao testes, Tabela 7.24, pode ser visualizados na Figura 7.28.

Figura 7.28 - Curvas ROC dos resultados dos testes, com pesos fixos, realizados com o classificador final (Tabela 7.24).

Como os testes realizados com as classes 1, 3 e 5 e as classes 1 e 5 utilizam um número maior de imagens do que no seu treinamento, foram acrescentadas mais 25 RIs às 110 RIs utilizadas nos treinamentos. Com isso, pode-se ter uma idéia do real acerto do classificador. Após os novos testes, cujos resultados estão na Tabela 7.25, foi observado que houve uma redução no acerto total da rede, principalmente devido à classe 3, que é a classe mais complexa. Ainda assim, o Az se manteve alto (0,98) com FN igual a 5% e FP igual a 7%. A curva ROC referente ao teste, Tabela 7.26, pode ser visualizado através da Figuras 7.29. A porcentagem de acerto médio ficou em 89%.

Tabela 7.25 - Testes percentuais realizados com o Classificador Final, utilizando 135 imagens.

Classes	MLP					
	% de Acertos por Classe					% Média de Acerto
	1	2	3	4	5	
1,2,3,4 e 5	82	95	73	95	86	89

Tabela 7.26 - Testes realizados com o Classificador Final, utilizando 135 imagens.

Classes		MLP				
		% nódulos por contorno				Az
Benignas	Malignas	VP	FN	FP	VN	
1, 2,	3, 4 e 5	95	5	7	93	0,98

Com base nos resultados, o treinamento escolhido para compor o Classificador Final foi o conjunto formado pelas classes 1, 2, 3, 4 e 5, obtido pela Rede Neural MLP com topologia de 20 neurônios de entrada, 40 neurônios na primeira camada intermediária, 20 neurônios na segunda cama intermediária e 5 neurônios na camada de saída, com taxa de aprendizagem igual a 0,9 e erro menor que 0,01. As 20 entradas foram selecionada através da Rede SOM e Gaussianas.

a) Classes 1,2,3,4 e 5 - Az = 0,98

Figura 7.29 - Curvas ROC dos resultados dos testes, com pesos fixos, realizados com o classificador final (Tabela 7.26).

Além do objetivo de se obter uma significativa classificação para os contornos de nódulos de mama, também estudou-se a melhor forma de apresentação dos resultados, na interface de saída do esquema, para que a informação possa ser passada de modo claro.

A finalidade é apresentar não apenas um resultado e sim todas as informações obtidas sobre o contorno. Dessa forma, estão sendo apresentados todos os resultados que a Rede MLP obteve de cada contorno de nódulo. Nas Figuras de 7.30 a 7.34 está sendo demonstrado como o classificador apresenta o resultado da classificação de cada categoria que está sendo investigada. Por exemplo, a Figura 7.30 mostra que o classificador recebeu como entrada uma RI com contorno circunscrito; a resposta dada por ele demonstrou que esta RI tem 99,97% de chance de ter um contorno circunscrito, 0,13% de ser obscurecido, 0% de ser Microlobulado ou Mal definido e 0,02% de ser espiculado. Analogamente, o mesmo é apresentado quando se trata de outra categoria de contorno, conforme Figura 7.31 a 7.34.

Contorno

Circunscrito	Obscurecida	Microlobulada	Mal Definida	Espiculada
99,97%	0,13%	0%	0%	0,02%

Figura 7.30 - Classificação do contorno Circunscrito.

Contorno

Circunscrito	Obscurecida	Microlobulada	Mal Definida	Espiculada
0%	96,98%	0,48%	0%	0,02%

Figura 7.31 - Classificação do contorno Obscurecido.

Contorno

Circunscrito	Obscurecida	Microlobulada	Mal Definida	Espiculada
1,93%	8,81%	95,53%	1,11%	0,11%

Figura 7.32 - Classificação do contorno Microlobulado.

Contorno

Circunscrito	Obscurecida	Microlobulada	Mal Definida	Espiculada
0%	1,72%	14,47%	99,03%	0,1%

Figura 7.33 - Classificação do contorno Mal Definido.

Contorno

Circunscrito	Obscurecida	Microlobulada	Mal Definida	Espiculada
6,69%	0%	0,02%	0%	93,84%

Figura 7.34 - Classificação do contorno Espiculado.

Na Figura 7.35 é apresentada a interface do classificador final a ser acrescentado ao Esquema CAD em desenvolvimento pelo LAPIMO.

Figura 7.35 - Classificador de contornos de nódulos mamários.

7.2.7 - Conclusões

A diferenciação dos contornos das classes 1 e 2 (circunscrita e obscurecida), classes 4 e 5 (mal definida e espiculada) e classes 2 e 4 (obscurecida e mal definida) é complexa, trazendo muita dificuldade na separação das imagens, como pôde ser verificado nos testes descritos no item 7.2.6. Lá os testes realizados com as classes 1, 3 e 5 levaram a um bom desempenho no treinamento; porém, os testes com o classificador final apresentaram baixo desempenho, pois as classe 2 e 4, que são de certa forma parecidas, acabaram sendo classificadas de forma incorreta.

Através das características extraídas pelos métodos de processamento de imagens e pela seleção dos melhores atributos, de acordo com a metodologia aqui descrita, foi possível obter um Az igual a 0,98, FN igual a 5% e FP igual a 7%, o que representa uma boa confiabilidade da classificação para os cinco tipos de contornos de nódulos mamários. Esse esquema de classificação foi incorporado ao Esquema CAD que está sendo desenvolvido pelo LAPIMO.

8 - CONCLUSÕES

O uso de descritores de textura para esquemas CAD vem sendo muito estudado atualmente. Embora fique difícil o entendimento da utilização de textura para a classificação de contorno, os descritores de textura fornecem medidas, como suavidade, rugosidade e regularidade, as quais, isoladamente, não produzem bons resultados para a classificação de contorno; mas, junto com outras técnicas, podem contribuir no que diz respeito a informações sobre a variação de intensidade ou alterações sutis entre o objeto e o fundo da imagem. Por exemplo, a textura contida em uma imagem com contorno espiculado é visualmente diferente de uma imagem com contorno circunscrito. Com base nessas informações, nosso estudo focou a utilização de atributos de textura associados com outros descritores a fim de classificar imagens de contorno de nódulos mamários em cinco categorias. Essa classificação tem como objetivo principal associar um conjunto de informações pré-definidas com base em atributos que identifique a melhor classe que irá caracterizar o caso em estudo.

A tarefa de classificação ocorre em várias áreas da atividade humana e as pesquisas na área têm sido bastante direcionadas à construção de procedimentos automáticos de classificação para esquemas CAD. Além dos estudos envolvendo a classificação, outras técnicas vêm sendo estudadas para melhorar a separação de classes, reconhecimento de padrões e tomada de decisões.

Foi possível observar que a seleção dos atributos que melhor representam cada classe irá realmente melhorar a performance do classificador e, com isso, aumentar sua precisão. Nas comparações realizadas entre as duas redes neurais para a separação de nódulos (1ª Fase dos Experimentos) foi possível observar que, por exemplo, no caso da Rede Neural MLP, antes da seleção dos melhores atributos de textura, o classificador

estava registrando 86,67% de acerto na fase de testes; mas, após a seleção das melhores características, aumentou seu nível de precisão na fase testes em 5,57%. E com a Rede Neural SOM, antes da seleção dos melhores atributos de textura, a variação do nível de acertos foi de mais 5,11% (de 81,66% para 85,83%). Na 2ª Fase dos Experimentos a seleção dos melhores atributos apresentou bons resultados (valores acima de 80%) em todos os testes realizados, mostrando, assim, que tal seleção melhora os resultados do classificador em todos os modelos verificados.

Levando em consideração as 20 atributos, que foram selecionadas através da Rede Neural SOM e análise da distribuição Gaussiana, foi possível obter o melhor resultado de treinamentos para as classes 1, 2, 3, 4 e 5. Foram obtidos pela Rede Neural MLP com topologia de 20 neurônios de entrada, 40 neurônios na primeira camada intermediária, 20 neurônios na segunda camada intermediária e 5 neurônios na camada de saída, com taxa de aprendizagem igual a 0,9 e erro menor que 0,01.

Outro dado constatado foi que a análise realizada pelo especialista continua sendo bastante subjetiva e a identificação de uma lesão como suspeita ou não e sua detecção dependem muito da experiência do médico. Essa é mais uma motivação para o uso de ferramentas automáticas para o auxílio ao diagnóstico, que tentam fornecer uma análise baseada em dados mais objetivos através de valores extraídos da própria imagem. O objetivo aqui foi estabelecer um processo de classificação de contorno que apresente não apenas uma resposta simples, mas retorne ao especialista todo o conjunto de conhecimento extraído dos contornos, fornecendo assim, o percentual de quanto aquela RI pertence individualmente a cada uma das classes consideradas.

O objetivo inicial deste trabalho era utilizar apenas as Redes Neurais Artificiais SOM para classificar imagens de nódulos mamários por contorno. Porque, existia um número reduzido de RIs com laudos por contorno, na nossa base de imagens mamográficas (Benatti *et al*, 2001), que fossem suficientes para os testes com uma rede supervisionada. Os testes iniciais realizados com a rede SOM, utilizando as cinco classes, não apresentaram bons resultados. Todavia, a partir dessa fase de testes, a base de imagens incorporou um conjunto significativo de imagens, várias com laudos por contorno, aumentando a base de testes para 135 RIs. Foi então que se acrescentaram ao trabalho os testes com a Rede Neural Artificial MLP.

No início existiam várias dúvidas sobre a possibilidade de classificar as RIs nas 5 classes estudadas, pois, ao longo de toda a revisão bibliográfica não foi encontrado nenhum trabalho com as 5 classificações (apenas um trabalho de Rangayyan & Nguyen

(2005) utilizava a classificação de duas classes sendo a circunscrita - classe 1 - e a espiculada - classe 5 - com Az variando de 0,93 a 0,98). Por isso, foram realizados vários testes com diversas combinações de classes, a fim de verificar qual a combinação que iria fornecer o melhor acerto. Apenas não se tinham dúvidas de que as classes 1 e 5 iriam apresentar sempre bons resultados já que a estrutura da imagem, e a forma, entre outras características, são bem definidas.

No decorrer do desenvolvimento deste trabalho várias técnicas foram estudadas a fim de aplicar outro tipo de detector de borda, para obter uma maior precisão do contorno do nódulo; no entanto, por ora, foi mantida a segmentação através de *Watershed* já presente na etapa de segmentação de nódulos do Esquema CAD (Santos *et al.*, 2002).

Assim os objetivos iniciais foram alcançados, pois foi possível classificar as 5 classes com uma média total de acerto igual a 89% e Az igual a 0,98 com FN de 5% e FP de 7%. Se compararmos com a revisão bibliográfica, podemos verificar que o resultado obtido se encontra entre os melhores resultados publicados até hoje nesse tópico específico, com o diferencial de estarmos classificando cinco classes de contorno.

Ainda existe muito a ser estudado, será necessário validar o classificador com um número maior de imagens, mas consideramos que os presentes resultados representam um bom avanço nas pesquisas com a classificação automática de contorno de nódulo.

8.1 - Trabalhos Futuros

A continuidade deste trabalho pode aprofundar as pesquisas no sentido de aprimorar o esquema de classificação desenvolvido. Para isto, apresentam-se algumas sugestões:

- a) Realização de testes com outros conjuntos de imagens, de outros bancos de imagens mamográficas, que particularmente estejam disponíveis laudos de biópsia;
- b) Estudar outras técnicas de detecção de contorno.

REFERÊNCIAS BIBLIOGRÁFICAS

- ADALSTEINSSON, D.; SETHIAN, J. (1999) *A. The Fast Construction of Extension Velocities in Level Set Methods*. Journal of Computational Physics, v. 148, pp. 2–22.
- ALMASI, G. S.; GOTTLIEB, A. (1994) *Highly parallel computing*. 2ed. Redwood City:Benjamin/Cummings.
- ANDRÉ, T. C. S. S.; RANGAYYAN, R. M. (2003) *Classification of Tumors and Masses in Mammograms Using Neural Networks with Shape and Texture Features*. Proceedings of the 25th Annual International Conference of the IEEE EMBS, Cancun, Mexico, Setembro 17-21, pp. 2261-2264.
- ANDERSEN, C.H; ESSICK, G.K.; SIEGEL, R.M. (1985) *Encoding of spatial location by posterior parietal neurons*. Science, v. 230, pp. 456-458.
- ARBACH, L.; BENNETT, D. L.; REINHARDT, J. M.; FALLOUH, G. (2003) *Mammographic Masses Classification: Comparison Between Backpropagation Neural Network (BNN), K Nearest Neighbors (KNN), and Human Readers*. IEEE CECE, Montréal, Maio, pp. 1441-1444.
- AZEVEDO, F. M. de; BRASIL, L. M.; OLIVEIRA, R. C. L. de. (2000) *Redes Neurais com Aplicações em Controle e em Sistemas Especialistas*. Florianópolis, ed. Visual Books, 401p.
- BALL, J. E.; BUTLER, T.W; BRUCE, L.M. (2004) *Towards Automated Segmentation and Classification of Masses in Digital Mammograms*. Proceedings of the 26th Annual International Conference of the IEEE EMBS, San Francisco, CA, USA, pp. 1814-1817.
- BALLARD, D. H.; BROWN, C. M. (1982) *Computer Vision*. Prentice Hall, 523p.

BENATTI, R.; SCHIABEL, H.; NUNES, F.L.S. (2001) *Construção de uma base de mamogramas digitalizados para utilização em sistemas de diagnóstico auxiliado por computador*. In: XXIV Encontro Nacional de Física da Matéria Condensada, São Lourenço, anais p.30.

BILSKA-WOLAK, A. O.; Floyd, C. E.; Lo, J. Y.; Baker, J. A. (2005) *Computer Aid for Decision to Biopsy Breast Masses on Mammography: Validação on New Cases*. Academic Radiology, Junho, v. 12, no. 6, pp. 671-680.

BLAND, K. I.; COPELAND, E.M. (1994) *A Mama: Tratamento Compreensivo da Doenças Benignas e Malignas*. Ed. Manole Ltda.

BOTTIGLI, U.;GOLOSIO, B. (2002) *Feature extraction from mammographic images using fast marching methods*. Nuclear Instruments and Methods in Physics Research A, v. 487, pp. 209–215.

BOYD, N.F.; BYNG, J.W.; JONG, R.A.; FISHELL, E.K.; LITTLE, L.E.; MILLER, A.B.; LOCKWOOD, G.A.; TRITCHLER, D.L.; YAFFE, M.J. (1995) *Quantitative classification of mammographic densities and breast cancer risk: results from the canadian national breast screening study*. Journal of the National Cancer Institute, v. 87, pp. 670-675.

BRAGA, A. P.; CARVALHO, A.C.P.L.F. (2000) *Redes Neurais Artificiais: Teoria e Aplicações*. Rio de Janeiro: LTC Editora, 262 p.

BURREL, H. C.; SIBBERING, D. M.; WILSON, A. R; PINDER, S. E.; EVANS, A. J.; YEOMEN, L. J.; ELSTON, C. W.; ELLIS, I. O.; BLAMEY, R. W. (1996) *Screening interval breast cancers: Mammographic features and prognostic factors*. Radiology, v. 199, pp. 811–817.

CASELLES,V.; CATTE, F.; COLL, T.; DIBOS, E. (1993) *A geometric model for active contours*. Numerische Mathematik, pp. 66:l-31.

COHEN, L. D. (2001) *Multiple Contour Finding and Perceptual Grouping using Minimal Paths*. Journal of Mathematical Imaging and Vision, v. 14, pp. 225–236.

CURRY III, T.S.; DOWDEY, J.E.; MURRY, R.C. (1990) *Christensen's Physics of Diagnostic Radiology*. 4th ed. Lea & Febiger, Philadelphia, USA..

COSTA, L.F.; CÉSAR, R.M. (2001) *Shape analysis and classification: theory and practice* - CRC Press.

DIAS, E. N. (1994) *A mastologia através da história*. In: Mastologia Atual (E. N. Dias, M. Caleffi, H. M. S. Silva & A. S. S. Figueira Filho, org.), Rio de Janeiro: Editora Revinter, pp. 3-6.

DOI, K.; GIGER, M. L.; NISHIKAWA, R.M.; HOFFMAN, K. R.; MACMAHON H.; SCHMIDT, R. A.; METZ, C. E., (1995) *Recent Progress in Development of Computer-Aided Diagnosis (CAD) Schemes In Radiology*. Medical Image Technology, Nov., v. 13, n. 6, pp. 822-835.

DOI, K.; MACMAHON, H.; KATSURAGAWA, S.; *et al.* (1997) *Computer-aided diagnosis in radiology: potencial and pitfalls*. Eur. J. Radiol. v.31, pp. 97-109.

DOI, K; MACMAHON, H.; GIGER, ML; HOFFMANN, K. R. (1999) *Computer-aided diagnosis and its potencial impact on diagnostic radiology*. Computer-aided diagnosis in medical imaging. Amsterdam: Elsevier Science, pp.11-20.

DUDA, R.O, *et al.*, (1973) *Pattern Classification and Scene Analysis*. John Wiley & Sons, New York.

DUDA, R.O, NITZAN, D.; BARRET, P. (1979) *Uses of Range and Reflectance Data to Find Surface Regions*. IEEE Transactions on Pattern Analysis and Machine Intelligence, July , v. PAMI-1, no. 3, pp. 259-271.

EFRON, B.; TIBSHIRANI, R. J. (1998) *An Introduction to the Bootstrap*. Boca Raton, FL: CRC Press LLC.

ELLIOTT, E.B. (1913) *An introduction to the Algebra of Quantic*. Chelsea Publishing Company, Bronx, New York.

EVANS, A. L. (1981) *The evaluation of medical images*. Adam Hilger Ltd, Bristol, Great Britain, p.129.

FUKUNAGA, K. (1990) *Introduction to Statistical Pattern Recognition*, Second Edition.

GEORGIU, H. V.; MAVROFORAKIS, M. E.; CAVOURAS, D.; DIMITROPOULOS, N.; THEODORIDIS, S. (2002) *Multi-resolution Morphological Analysis and Classification of Mammographic Masses Using Shape, Spectral and Wavelet Features*. IEEE, pp. 465-468.

GIGER, M. L. (1999) *Computer Aided Diagnosis*. RSNA Categorical Course in Breast Imaging, pp. 249-272.

GIULIANO et al. - GIULIANO, V. E., JONES, P. E; KIMBALL, G.E., MEYER, R. F.; STEIN, B. A. (1961). *Automatic Pattern Recognition by a Gestalt Method*. Information and Control, v. 4, pp. 332-345.

GOMES, R., SKABA, M. M. V. F.; VIEIRA, R. J. da S. (2002). *Reinventando a vida: proposta para uma abordagem sócio-antropológica do câncer de mama feminina*. Cad. Saúde Pública, jan./fev., v.18, no.1, pp.197-204.

GONZALES, R.C.; WOODS, R.E.; (2000) *Processamento de imagens digitais*. Tradução Roberto M. Cesar Junior e Luciano da Fontoura Costa. São Paulo: Editora Edgard Blücher Ltda, p. 509.

GONZALES, R.C.; WOODS, R.E. (2001) *Digital Image Processing*, 2nd ed. Prentice Hall, New Jersey/USA.

GONZALES, R. C.; WOODS, R. E. (2002) *Digital Image Processing*, Second Edition, Editora: Prentice Hall, New Jersey, p. 793.

GOSE, E.; et al.. (1996) *Pattern Recognition and Image Analysis*. Prentice Hall, NJ.

GUREVICH, G. B. (1964) *Foundations of the Theory of Algebraic Invariants*. Nordoff, Groningen, The Netherlands.

HANLEY, J. A.; MCNEIL, B. J. (1982) *The Meaning and Use of the Area under a Receiver Operating Characteristic (ROC) Curve*. Radiology, v. 143, pp. 29–36.

HANLEY, J. A.; MACNEIL, B. J. (1983) *A Method of Comparing the Areas Under Receiver Operating Characteristic Derived From the Same Cases*. Radiology, Sep., v. 148, pp. 839-43.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. (1973) *Textural Features for Image Classification*. IEEE Transactions on Systems Man, and Cybernetics, Vol-SMC 3, n.6.

HARALICK, R. M. (1979) *Statistical and structural approaches to texture*. Proceedings of the IEEE. May, v. 67, n. 5, p. 786-804.

HAYKIN, S. (1994) *Neural Networks: A Comprehensive Foundation*. Macmillan Publishing Co:/ IEEE Press.

HEBB, D. (1949) *Organization of Behavior*. John Willy & Sons, New York.

HERTZ, J.; JROCH, A.; PALMER, R.G. (1991) *Introduction to the theory of Neural Computation*. Addison-Wesley Publishing Company, CA.

HEYWANG-KÖBRUNNER, S. H; SCHREER, I; DERSHAW, D.D; FRANSSON, A. (1999) *Mama - Diagnóstico por Imagem*. Revinter, p. 412.

HORN, R. A.; JOHNSON, C. R. (1996) *Matrix Analysis*. Cambridge University Press, p. 561.

HU, M. K. (1961) *Pattern Recognition by Moments Invariants*. Proc. of the IRE, v. 49, n. 9, p.1428.

HU, M. K. (1962) *Visual Pattern Recognition by Moments Invariants*. IRE Trans. Inf. theory, v.8, pp. 179-187.

JIANGA, Y.; BABYNB, P. (2004) *X-ray bone fracture segmentation by incorporating global shape model priors into geodesic active contours*. International Congress Series, v. 1268, pp. 219–224.

KASS, M.; WITKIN, A.; TERZOPOULOS, D. (1988) *Snakes: Active Contour Models*. International Journal of Computer Vision, 1(4), pp. 321-331.

KOHONEN, T. (1984) *Self-organizing and Associative Memory*. Springer-Verlag, Berlin, v1.

KOPANS, D. B. (1992) *The positive predictive value of mammography*. AJR Am J Roentgenol, v. 158, pp. 521-526.

KOPANS, D. B. (2000) *Imagem da Mama*. Rio de Janeiro, MEDSI, p. 852.

LAGOEIRO, F.G. (2004). *Interface e Integração de Esquemas de Processamento de Imagens para Avaliação Automática de Mamogramas Digitalizados*. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, Brasil.

LANCHENBRUCH, P. A. (1975) *Discriminant Analysis*. New York: Hafner.

LEVINE, M. D. (1985) *Vision in Man and Machine*. McGraw-Hill, p. 574.

LIAPIS, S.; SIFAKIS, E.; TZIRITAS, G. (2004) *Colour and texture segmentation using wavelet frame analysis, deterministic relaxation, and fast marching algorithms*. J. Vis. Commun. Image R., v. 15, pp. 1–26.

LI, L.; ZHENG, Y.; ZHANG, L.; CLARK, R. (2001) *A. False-positive reduction in CAD mass detection using a competitive classification strategy*. Medical Physics, Fev., v. 28, no. 2, pp. 250-258.

LIU, Y.; SMITH, M. R.; RANGAYYAN, R. M. (2004) *The Application of Efron's Bootstrap Methods in Validating Feature Classification using Artificial Neural Networks for the Analysis of Mammographic Masses*. Proceedings of the 26th Annual International Conference of the IEEE EMBS, San Francisco, CA, USA, September 1-5, pp. 1553-1556.

MALLADI, R.; SETHIAN, J. A.; VEMURI, B. C. (1995) *Shape Modeling with Front Propagation: A Level Set Approach*. IEEE Transactions on Pattern Analysis and Machine Intelligence, Fev., v. 17, n. 2, pp. 158-175.

MALLADI, R.; SETHIAN, J. (1996) *A. An $O(N \log N)$ algorithm for shape modeling*. Proc. Natl. Acad. Sci. USA, September, v. 93, pp. 9389–9392.

MARAR, J. M.; CARVALHO FILHO, E. C. de B. (1994) *Reconhecimento de Padrões Numéricos Através da Transformada Karhunen-Loève*. VII SIBGRAPI, pp. 229-234.

MARKEY, M. K.; LO, J. Y.; TOURASSI, G. D.; FLOYD Jr., C. E. (2003) *Self-organizing map for cluster analysis of a breast cancer database*. Artificial Intelligence in Medicine, February, v. 27, n. 2, pp. 113-127.

MASCARENHAS, N. D. A.; VELASCO, F. R. D. (1989) *Processamento Digital de Imagens*. Editorial Kapelusz S.A., Buenos Aires, Argentina.

MAVROFORAKIS, M. E.; GEORGIU, H. V.; CAVOURAS, D.; DIMITROPOULOS, N.; THEODORIDIS, S. (2002) *Mammographic Mass Classification Using Textural Features and Descriptive Diagnostic Data*. IEEE, pp. 461-464.

MAVROFORAKIS, M.; GEORGIU, H.; DIMITROPOULOS, N.; CAVOURAS, D.; THEODORIDIS, S. (2005) *Significance analysis of qualitative mammographic features, using linear classifiers, neural networks and support vector machines*. European Journal of Radiology, Abril, v. 54, ed. 1, pp. 80-89.

MCCARTHY, J. (1963) *A basis for a mathematical theory of computation*. North Holland, pp. 33-70.

MCCULLOCH, W. S.; PITTS, W. H. (1943) *A logical calculus of the ideas immanent in nervous activity*. Bulletin of Mathematical Biophysics, v. 5, n. 1, pp. 115-133.

MCINERNEY, T.; TERMPOULOS, D. (1996) *Deformable models in medical image analysis: a survey*. Med. Imag. Anal., 1(2):91-108.

METZ, C. E. (1978) *Basic Principles of ROC Analysis*. Seminars in Nuclear Medicine, VIII (4):283-298.

METZ, C. E. (1986) *ROC Methodology in Radiologic Imaging*. Investigative Radiology, v. 21, pp. 720-733.

MEYER, J. E.; EBERLEIN, T. J.; STOMPER, P. C., et al. (1990) *Biopsy of occult breast lesions: analysis of 1261 abnormalities*. JAMA, v. 263, pp. 2341-2343.

MINSKY, M. L.; PAPERT, S. A. (1969) *Perceptrons: a introduction to computational geometry*. The MIT Press, Massachusetts.

MITCHELL Jr., G. W.; BASSET, L. W. (1988) *Mastologia Prática*. Revinter.

MITCHELL, T. M. (1997) *Machine Learning*. WCB/McGraw-Hill.

MUDIGONDA, N. R.; RANGAYYAN, R. M.; DESAUTELS, J. E. L. (2000) *Gradient and Texture Analysis for the Classification of Mammographic Masses*. IEEE Transactions on Medical Imaging, Outubro, v. 19, n. 10, pp. 1032-1043.

MUDIGONDA, N. R.; RANGAYYAN, R. M.; DESAUTELS, J. E. L. (2001) *Detection of Breast Masses in Mammograms by Density Slicing and Texture Flow-Field Analysis*. IEEE Transactions on Medical Imaging, Dezembro, v. 20, n. 12, pp. 1215-1227.

NISHIKAWA, R.M.; GIGER, M.L.; DOI, K.; VYBORNÝ, C. J.; SCHMIDT, R.A. (1993) *Computer-Aided detection and diagnosis of masses and clustered microcalcifications from digital mammograms*. State of the art in Digital Mammographic Image Analysis.

NUNES, F. L. (2001). *Investigações em processamento de imagens mamográficas para auxílio ao diagnóstico de mamas densas*. 208p. Tese (Doutorado) - Instituto de Física de São Carlos, Universidade de São Paulo, São Carlos.

PATROCINIO, A. C.; SCHIABEL, H.; GOES, C. E.; BENATTI, R. H.; NUNES, F. L. S. (2000) *Investigation of clustered microcalcification features for an automated classifier as part of a mammography CAD Scheme*. In: World Congress on Medical Physics and Biomedical Engineering, Cd Rom Proc. of The World Congress On Medical Physics And Biomedical Engineering, Chicago.

PATROCINIO, A. C.; SCHIABEL, H.; ROMERO, R. A. F. (2001) *Classifier scheme for clustered microcalcifications in digitized mammograms by using artificial neural networks*. In: V Congresso Brasileiro de Redes Neurais, Rio de Janeiro.

PATROCINIO, A. C.; SCHIABEL, H.; ROMERO, R. A. F. (2001) *Classifying clusters of microcalcifications in digitized mammograms by artificial neural networks*. In: 14th Brazilian Symposium, on Computer Graphics and Image Processing, 2001. Proceedings of SIBGRAPI 2001, IEEE Computer Society. Washington DC: IEEE Computer Society, Florianópolis, pp. 266-272.

PATROCINIO, A. C.; SCHIABEL, H.; ROMERO, R. A. F. (2004) *Evaluation of Bayesian Network to classify clustered microcalcifications*. Medical Image 2004 - Image Processing. Proceedings of SPIE, San Diego (CA) - USA, v. 5370, pp.1026-1033.

PATROCINIO, A. C. (2004) *Classificador automático de achados mamográficos em imagens digitais de mamas densas utilizando técnicas híbridas*. Tese (Doutorado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

PARKER, J. R. (1997) *Algorithms for Image Processing and Computer Vision*. Wiley Computer Publishing, 417p.

PRATT, W. K. (1991) *Digital Image Processing*. A Wiley-Interscience Publication.

QUADROS, L. G. de A. (2003) *Classificação Bi-Rads® para laudos de mamografia*. Revista Brasileira de Mastologia, v. 13, n. 4, pp. 147.

QUINN, M. J. (1994) *Parallel computing: theory and practice*. 2ed. New York: McGraw-Hill.

RANGAYYAN, R. M.; MUDIGONDA, N. R.; DESAUTELS, J.E.L. (2000) *Boundary Modelling and Shape Analysis Methods for Classification of Mammographic Masses*. Medical and Biological Engineering and Computing, v. 38, pp. 487-495.

RANGAYYAN, R. M.; NGUYEN, T. M. (2005) *Pattern Classification of breast masses via fractal analysis of their contours*. International Congress Series, Maio, v. 1281, pp. 1041-1046.

RIBEIRO, P. B; SCHIABEL, H.; PATROCINIO, A. C.; MARAR, J. F. (2005) *Utilização de Atributos de Textura de Haralick e Redes Neurais Artificiais para a Separação de Imagens Mamarias*. 4º Congresso Temático de Dinâmica, Controle e Aplicações, UNESP, Bauru, Série Arquimedes, Junho, v. 4, pp. 1216-1233.

RIBEIRO, P. B; SCHIABEL, H.; PATROCINIO, A. C. (2005) *Utilização de Distribuições Gaussianas para a Seleção dos Melhores Atributos de Textura*, SIIM 2005 - 2º Simpósio de Instrumentação e Imagens Médicas, São Pedro, Brasil

RIBEIRO, P. B; PATROCINIO, A. C.; SANTOS, V. T.; SCHIABEL, H. (2005) *Classificação de imagens mamográficas através de análise de textura*, Congresso Brasileiro de Radiologia 2005, Brasília, Brasil.

RIBEIRO, P. B; SCHIABEL, H.; PATROCINIO, A. C.; ESCARPINATI, M.C. (2005) *Comparativo entre a classificação de duas Redes Neurais Artificiais na separação de imagens mamográficas*, 5º Encobio - Encontro de Bioengenharia. 2005, USP, São Carlos, Brasil.

RIBEIRO, P. B; SCHIABEL, H.; PATROCINIO, A. C. (2006) *Classificação de Imagens Mamograficas por Análise de Textura dos Nódulos*, CBFM - Congresso Brasileiro de Física Médica, 14 a 17 Junho, Ribeirão Preto, Brasil.

RIBEIRO, P. B; SCHIABEL, H.; PATROCINIO, A. C. (2006) *Improvement in ANN Performance by the Selection of the Best Texture Features from Breast Masses in Mammography Images*, WC 2006 - World Congress on Medical Physics and Biomedical Engineering 2006, 27 Agosto - 1 Setembro, Seoul, Korea.

RIBEIRO, P. B; SCHIABEL, H.; PATROCINIO, A. C.; ROMERO, R. A. F. (2006) *A Influência da Seleção de Melhores Atributos na Classificação de Contornos de Nódulos de Mama Através de RNA*, XX CBEB - Congresso Brasileiro de Engenharia Biomédica - Hotel Fazenda Fonte Colina Verde, 22 a 26 de outubro, São Pedro, Brasil.

ROSENBLATT, F. (1958) *The perceptron: a probabilistic model for information storage and organization in the brain*, Psychological Review, v. 65, n. 1, pp. 386-408.

RUMELHART, D. E.; WILLIAMS, R.J.(1986). *Learning internal representations by error propagation*. Parallel distributed processing, v 1, p.318-62

SANTAELLA, C. H. de M.; SCHIABEL, H.; PATROCINIO, A. C.; NUNES, F. L S; ROMERO, R. Ap. F. (2003) *Classification of nodules in mammograms image by using wavelet transform*. Medical Imaging 2003: Image Processing. Proceedings of SPIE, San Diego (CA) - USA, v. 5032, n. 1605-7422, pp. 908-918.

SANTOS, V.T; SCHIABEL, H.; GOES, C.E. (2002) *A Segmentation Technique to Detect Masses in Dense Breast Digitized Mammograms*. Journal of Digital Imaging, may, v. 15, Suppl. 1, pp. 210-213.

SCHALKOFF, R. J. (1989) *Digital Image Processing*. John Wiley & Sons, Inc., New York.

SETHIAN, J. A. (1996) *A fast marching level set method for monotonically advancing fronts*. Proc. Natl. Acad. February, v. 93, pp. 1591-1595.

SETHIAN, J. A. (1998) *Adaptive Fast Marching and Level Set Methods for Propagating Interfaces*. Acta Math. Univ. Comenianae, V. LXVII, n. 1, pp. 3-15.

SETHIAN, J. A. (1999) *Fast Marching Methods*. SIAM Review, Junho, v. 41, n. 2, pp. 199-255.

SETHIAN, J. A. (2001) *Evolution, Implementation, and of Level Set and Fast Marching for Advancing Fronts*. Journal of Computational Physics, v. 169, pp. 503-555.

SIFAKIS, E.; TZIRITAS, G. (2001) *Moving object localisation using a multi-label fast marching algorithm*. Signal Processing: Image Communication, v. 16, pp. 963-976.

SONKA, M.; HLAVAC, V.; BOYLE, R. (1999) *Image Processing, Analysis and Machine Vision*. Chapman & Hall, 555p.

STERNS, E. E. (1996) *Relation between clinical and mammographic diagnosis of breast problems and the cancer/biopsy rate*. Can. J. Surg., v. 39, n. 2, pp. 128-132.

STRACHAN, N.J.C.L; NESVADBA, P.; ALLRN, A.R. (1990) *Fish species recognition by shape analysis of images*. Pattern Recognition, v. 23, n. 5, pp. 539-554.

TAFNER, M. A.; XEREZ, M. de; RODRIGUES FILHO, I. W. (1996) *Redes Neurais Artificiais: Introdução e princípios de neurocomputação*. Blumenau, ed. FURB, , 200p.

TANENBAUM, A. S.; STEEN, M. (2002) *Distributed systems: principles and paradigms*. Upper Saddle River, N.J: Prentice Hall.

TAO, E. Y.; ORNES, C.; SKLANSKY, J. (1998) *Fully automatic detection of microcalcifications in digital mammography*. SPIE 98 - Image Processing, v. 3338, p. 1450-1458.

VIEIRA, M. A. C. (2005) *Metodologia Baseada nas Funções de Transferência para Pré-processamento de imagens Mamográficas Digitais e sua Aplicação em Esquema Computacional de Auxílio ao Diagnóstico*. Tese (Doutorado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, Brasil.

VELTHUIZEN R. P. (2000) *Computer diagnosis of mammographic masses*. Precessings of the 29th IEEE Applied Imagery Pattern Recognition Workshop, pp. 166-172.

VIEIRA, M. A. C. (2005) *Metodologia Baseada nas Funções de Transferência para Pré-processamento de Imagens Mamográficas Digitais e sua Aplicação em Esquema Computacional de Auxílio ao Diagnóstico*. Tese (Doutorado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, Brasil.

XU, C.; YEZZI Jr, A.; PRINCE, J. L. (2000) *On the Relationship between Parametric and Geometric Active Contours*. In Proc. of 34th Asilomar Conference on Signals, Systems, and Computers, Outubro, pp. 483-489.

WANG, X. H et. al. (1999) *Computer-Assisted Diagnosis of Breast Cancer Using a Data-Driven Bayesian Belief Network*. International Journal of Medical Informatics, v. 54, pp 116-126.

WIDROW, B.; HOFF, M. (1960) *Adaptive switching circuits*. In: IRE WESCON Convention Record, reprinted in Neurocomputing. J.A. Anderson & E. Rosenfeld edt., New York, pp. 96-104.

WOLBASRST, A. B.. (1993) *Physics of Radiology* Appleton & Lange, 461p.

YAN, J.; ZHUANG, T. (2003) *Applying improved fast marching method to endocardial boundary detection in echocardiographic images*. Pattern Recognition Letters, v. 24, pp. 2777-2784.

ZHENG, B.; et al.. (1999) *Feature Selection for Computerized Mass Detection in Digitized Mammograms by Using a Genetic Algorithm*. Acad. Radiology, 6: 327-332.

ZHENG, B.; SWENSSON, R. G.; GOLLA, S.; HAKIM, C. M.; SHAH, R.; WALLACE, L.; GUR, D. (2004) *Detection and Classification Performance Levels of Mammographic Masses Under Different Computer-Aided Detection Cueing Environments*. Academic Radiology, Abril, v. 11, ed. 4, pp. 398-406.

ZHENG, B. et al.. (1997) *Adequacy Testing of Training Set Sample Sizes in the Development of a Computer-assisted Diagnosis Scheme*. Acad Radiol, v. 4, pp. 497-502.

ZURADA, J. M. (1992) *Introduction to Artificial Neural Systems*. Republic of Singapore, West Info Access, 683p.

ZWIGGELAAR, R.; ASTLEY, S. M.; BOGGIS, C. R. M.; TAYLOR, C. J. (2004) *Linear Structures in Mammographic Images: Detection and Classification*. IEEE Transactions on Medical Imaging. Settembre, v. 23, n. 9, pp. 1077-1086.