UNIVERSIDADE DE SÃO PAULO

ESCOLA DE ENGENHARIA DE SÃO CARLOS

Departamento de Engenharia Elétrica

KAREM DAIANE MARCOMINI

APLICAÇÃO DE MODELOS DE REDES NEURAIS ARTIFICIAIS NA SEGMENTAÇÃO E CLASSIFICAÇÃO DE NÓDULOS EM IMAGENS DE ULTRASSONOGRAFIA DE MAMA

São Carlos

2013

KAREM DAIANE MARCOMINI

APLICAÇÃO DE MODELOS DE REDES NEURAIS ARTIFICIAIS NA SEGMENTAÇÃO E CLASSIFICAÇÃO DE NÓDULOS EM IMAGENS DE ULTRASSONOGRAFIA DE MAMA

Dissertação de mestrado 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 Ciências, Programa de Engenharia Elétrica.

Área de concentração: Processamento de Sinais e Instrumentação

Orientador: Prof. Dr. Homero Schiabel

São Carlos

2013

Trata-se da versão original.

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ma Marcomini, Karem Daiane
Aplicação de modelos de redes neurais artificiais na segmentação e classificação de nódulos em imagens de ultrassonografia de mama / Karem Daiane Marcomini; orientador Homero Schiabel. São Carlos, 2013.

Dissertação (Mestrado) - Programa de Pós-Graduação em Engenharia Elétrica e Área de Concentração em Processamento de Sinais e Instrumentação -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2013.

1. ultrassom. 2. redes neurais artificiais . 3. câncer de mama. 4. processamento de imagens. 5. classificação. I. Título.

FOLHA DE JULGAMENTO

Candidata: Bacharel **KAREM DAIANE MARCOMINI.**

Título da dissertação: "Aplicação de modelos de redes neurais artificiais na segmentação e classificação de nódulos em imagens de ultrassonografia de mama".

Data da defesa: 26/03/2013

Comissão Julgadora:	**Resultado:**
Prof. Associado **Homero Schiabel (Orientador)** (Escola de Engenharia de São Carlos/EESC)	APROVADA
Profª. Titular **Maria Cristina Ferreira de Oliveira** (Instituto de Ciências Matemáticas e de Computação/USP)	Aprovada
Prof. Associado **Antonio Adilton Oliveira Carneiro** (Faculdade de Filosofia, Ciências e Letras de Ribeirão Preto/USP)	Aprovada

Coordenador do Programa de Pós-Graduação em Engenharia Elétrica e Presidente da Comissão de Pós-Graduação:
Prof. Titular **Denis Vinicius Coury**

Este trabalho teve o apoio financeiro da FAPESP –
Fundação de Amparo à Pesquisa do Estado de São Paulo
Processo n° 2010/14194-3

Dedico...

Aos meus pais que sempre confiaram e acreditaram em mim, apoiando-me em meus sonhos.

AGRADECIMENTOS

Agradeço primeiramente a Deus por sempre iluminar meus caminhos, pelas oportunidades a mim concedidas, pela força conferida para enfrentar os desafios impostos, pois sem sua ajuda não seria capaz de superá-los.

Aos meus pais Romildo e Cida, que me forneceram toda a base de formação pessoal e profissional, por serem exemplos de força e perseverança, além do imenso amor, carinho, apoio, incentivo e orientações confiadas, pela compreensão diante das mais diversas circunstâncias.

Ao Prof° Homero por acreditar em meu potencial acadêmico, pela sua receptividade, paciência, apoio e incentivo ao longo do desenvolvimento desse trabalho.

Aos meus irmãos Claudinei e Kátia por estarem sempre ao meu lado, sendo espelhos quanto à dedicação e aos esforços para superar as dificuldades e atingir seus objetivos.

A toda minha família, aos meus sobrinhos Yan Matheus e Evelyn, que enchem minha vida de luz e alegria, fortificando os laços familiares.

À Grazi, amiga de infância muito importante e que esteve presente em todos os momentos, que mesmo diante da distância física proporcionada pelo tempo, permaneceu continuamente disposta a me aconselhar, apoiar, ajudar, corrigir, ... e animar. Lembrar-me-ei sempre das nossas contínuas horas conversando em que mal víamos o passar do tempo.

Ao Renan, grande amigo que pude conhecer durante a graduação, cuja convivência foi estendida até o mestrado, estando presente nas mais diversas circunstâncias, sempre empenhado a me auxiliar, compreender, opinar, ensinar, além de me aguentar nos momentos difíceis.

À Maria Angélica pela assídua convivência, que com o decorrer do tempo tornou-se muito mais que uma amiga. Ensinou-me muita coisa, inclusive a confiar mais em meu potencial, me tolerou nos momentos difíceis e me socorreu no

desespero. Pelos diversos momentos de descontração compartilhados (festas, piscina, além de muitos outros).

À Patricia pela confiança em mim depositada desde as aulas ministradas durante minha graduação, ao apoio, empenho e dedicação para que chegasse ao meio acadêmico, além do auxílio com o desenvolvimento desse projeto.

Aos amigos do LAPIMO, Renata, Débora, Luciana Verçosa, Paula Siqueira, Bruno Barufaldi, Roger, pela convivência agradável e enriquecedora, aos momentos de distração e conhecimentos compartilhados.

Aos amigos da pós: Luciana, Thais, Camila, Tati, Ana Paula, Marcelo, Ricardo, Fábio, Remy, William e Rafael, os quais eu pude ter uma maior convivência, além de muitos outros que por breves momentos (principalmente durante o cafezinho) despertaram uma grande amizade.

Aos múltiplos amigos que conheci em São Carlos, entre eles à Fernanda, Jéssica, Raissa, que irei guardar com grande carinho.

Aos inúmeros amigos do GOU que me fortificaram nos momentos de grandes dificuldades.

Ao Prof° Adilton pela sua dedicação, contribuição e valorosas sugestões com o projeto.

À Santa Casa de São Carlos e ao GIIMUS de Ribeirão Preto pela colaboração e auxílio no fornecimento das imagens ultrassonográficas.

À FAPESP pelo apoio financeiro prestado ao desenvolvimento dessa pesquisa.

RESUMO

MARCOMINI, K. D. (2013). *Aplicação de Modelos de Redes Neurais Artificiais na Segmentação e Classificação de nódulos em imagens digitais de ultrassonografia de mama*. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

Muitos procedimentos vêm sendo desenvolvidos para auxiliar no diagnóstico precoce do câncer de mama. Nesse âmbito, a ultrassonografia tornou-se uma ferramenta indispensável na distinção entre lesões benignas e malignas. Devido a subjetividade na interpretação de imagens, os esquemas CAD têm oferecido ao especialista uma segunda opinião mais precisa e confiável. Nesse propósito, essa pesquisa apresenta uma metodologia para a detecção e caracterização automática de achados ultrassonográficos da mama. Os ensaios tiveram por base a utilização de imagens obtidas por simuladores e, a partir de resultados consideráveis, foram aplicados sobre exames clínicos. O processo teve início com o emprego de um pré-processamento (filtro de *wiener*, equalização e filtro da mediana) para a minimização do ruído. Em seguida, cinco técnicas de segmentação foram averiguadas a fim de determinar a representação mais concisa. Dentre elas, a rede neural SOM mostrou-se como a mais relevante. Após a delimitação do objeto, foram definidas as características mais expressivas para a descrição morfológica do achado. Esses dados serviram de entrada para o classificador neural MLP. A acurácia alcançada durante o treinamento em imagens simuladas foi de 94,2%, produzindo um Az de 0,92. Para avaliar a generalização dos dados, foi efetuada a classificação com imagens desconhecidas ao sistema, tanto em simuladores quanto em exames clínicos, nesses casos a acurácia foi de 90% e 81%, respectivamente. O classificador proposto apresentou-se como uma importante ferramenta de auxílio ao diagnóstico em ultrassonografias de mama.

Palavras-chave: ultrassom, redes neurais artificiais, câncer de mama, processamento de imagens, classificação.

ABSTRACT

MARCOMINI, K. D. (2013). *Application of Artificial Neural Network Models in Segmentation and Classification of nodules in digital images of breast ultrasound*. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

Many procedures have been developed to assist in the early diagnosis of breast cancer. In this context, ultrasound has become an indispensable tool to distinguish benign and malignant lesions. Due to the subjectivity on interpreting images, CAD schemes have provided to the specialist a second opinion more accurate and reliable. Thus, this research presents a methodology for the automatic detection and characterization of breast sonographic findings. The tests were based the use of images obtained by simulators and, as considerable results, were applied to clinical examinations. The process was started employing of a preprocessing (wiener filter, equalization and median filter) to minimize noise. Then, five segmentation techniques were investigated to determine the most concise representation of the lesion contour, enabling to consider the neural network SOM the most relevant. After the delimitation of the object, the most expressive features were defined to the morphological description of the finding, generating the input data to the neural classifier MLP. The accuracy achieved during training with simulated images was 94.2%, producing an Az of 0.92. To evaluating the data generalization, the classification was performed with a group of unknown images to the system, both to simulators as to clinical trials, resulting in an accuracy of 90% and 81%, respectively. The proposed classifier proved to be an important tool for the diagnosis in ultrasonography breast.

Keywords: ultrasound, artificial neural network, breast cancer, image processing, classification.

LISTA DE FIGURAS

Figura 1.1 – Diagrama em bloco de um sistema geral de Diagnóstico Auxiliado por Computador (CAD) para imagens de ultrassom 26
Figura 2.1 – Modificações na qualidade da imagem dos anos 1985, 1990 e 1995 ... 33
Figura 2.2 – Aparelho portátil de ultrassom (Medisson) 35
Figura 2.3 – Estrutura interna de um transdutor 36
Figura 2.4 – Medição de uma linha básica de ultrassom 37
Figura 2.5 – Alguns exemplos dos diferentes tipos de transdutores 38
Figura 2.6 – Processo de formação de imagem utilizando um transdutor de matriz sequencial linear 39
Figura 2.7 – Representação da obtenção de imagens na varredura modo-A 40
Figura 2.8 – Processo de obtenção de imagem pela varredura modo-B 40
Figura 2.9 – Imagem modo-M 41
Figura 2.10 – Imagem ultrassônica de um pulmão mostrando fortes artefatos de reverberação 42
Figura 2.11 – Imagem ultrassônica com sombreamento acústico 43
Figura 2.12 – Formação do *speckle* 44
Figura 2.13 – (a) Forma definida redonda e (b) ovóide; (c) forma indefinida 46
Figura 2.14 – Contorno: (a) regular, (b) macrolobulado; Contorno irregular, podendo ser de aspecto (c) microlobulado, (d) espiculado, (e) angular e (f) indistinto 46
Figura 2.15 – Ecogenicidade: (a) anecóica, (b) hipoecóica, (c) isoecóica e (d) hiperecóica 47
Figura 2.16 – Ecotransmissão: (a) ausente, (b) reforço acústico, (c) sombra acústica bilateral e (d) sombreamento acústico 48
Figura 2.17 – Orientação: (a) horizontal e (b) vertical 48
Figura 3.1 – Histograma da imagem 53
Figura 3.2 – Histograma da imagem equalizada 54
Figura 3.3 – Modelo de uma típica rede SOM 56

Figura 3.4 – Ilustração de rede *Perceptron* multicamadas..... 61
Figura 4.1 – Imagem clínica de ultrassonografia da mama com as marcações do radiologista 65
Figura 4.2 – (a) Recorte da ROI; (b) resultado da detecção 65
Figura 4.3 – Imagens clínicas de ultrassonografia da mama adquiridas pelos equipamentos: (a) General Electric, (b) Medison, (c) Siemens G50, (d) Toshiba 67
Figura 4.4 – *Phantoms* comerciais adquiridos pelo GIIMUS..... 68
Figura 4.5 – *Phantoms* desenvolvidos pelo GIIMUS 69
Figura 4.6 – Imagens da ultrassonografia obtida por meio dos *phantoms*..... 70
Figura 4.7 – Imagem clínica de uma ultrassonografia da mama e o respectivo recorte da ROI 71
Figura 4.8 – Disposição inicial do contorno ativo 73
Figura 4.9 – Contorno delineado pelo radiologista 77
Figura 4.10 – Índice de desempenho: VP, FP, FN 78
Figura 4.11 – Distribuição Gaussiana sem sobreposição das curvas..... 83
Figura 4.12 – Distribuição Gaussiana com sobreposição das curvas..... 83
Figura 4.13 – *Software WEKA* 84
Figura 4.14 – Dados de entrada para o *software WEKA* 85
Figura 4.15 – Aplicação que une apenas os descritores mais relevantes 86
Figura 4.16 – *Multilayer Perceptron* (MLP) 87
Figura 4.17 – Treinamento da rede MLP 87
Figura 5.1 – (a) Imagem Original; (b) após a filtragem de Wiener; (c) com equalização; (d) com filtro da mediana 92
Figura 5.2 – Segmentação por (a) Contorno ativo; (b) Crescimento de região; (c) fuzzy c-means; (d) k-means; (e) SOM 94
Figura 5.3 – Pós-processamento aplicado após a segmentação por (a) contorno ativo; (b) crescimento de região; (c) fuzzy c-means; (d) k-means; (e) SOM..... 95
Figura 5.4 – Sobreposição do contorno à ROI original, após a segmentação, por (a) contorno ativo; (b) crescimento de região; (c) fuzzy c-means; (d) k-means; (e) SOM 96
Figura 5.5 – (a) Delimitação manual da lesão por um radiologista e (b) extração da área da lesão 97

Figura 5.6 – Algumas distribuições Gaussianas que não produziram bons resultados 99
Figura 5.7 – Distribuições gaussianas que produziram bons resultados.....101
Figura 5.8 – Seletor de características do *Weka – AttributeSelection*.....102
Figura 5.9 – Curva ROC adquirida a partir da melhor classificação da MLP 104
Figura 5.10 – Curva ROC da classificação em imagens simuladas.....105
Figura 5.11 – Exemplo da diferença morfológica entre as imagens simuladas clínicas 106
Figura 5.12 – Curva ROC da classificação em imagens clínicas 107
Figura 5.13 – Imagem simulada com reforço acústico 107
Figura 5.14 – Segmentação da imagem simulada com a presença de reforço acústico 108
Figura 5.15 – Imagem simulada com sombreamento acústico 109
Figura 5.16 – Segmentação da imagem simulada com a presença de sombreamento acústico 109
Figura 5.17 – Sistema de análise ultrassonográfica da mama.....111
Figura 5.18 – Segmentação inadequada 112
Figura 5.19 – Janela para alteração da intensidade máxima dos níveis de cinza...112
Figura 5.20 – Segmentação após a alteração dos parâmetros iniciais 113

LISTA DE TABELAS

Tabela 2.1 – Valores de densidade, velocidade e impedância acústica em diversos meios clínicos....35
Tabela 2.2 – Critérios de benignidade e malignidade na classificação dos nódulos mamários....49
Tabela 4.1 – Total de imagens clínicas obtidas em cada equipamento....64
Tabela 4.2 – Total de imagens clínicas com achado suspeito....66
Tabela 4.3 – Total de ROIs de ultrassonografias clínicas com achados suspeitos...71
Tabela 4.4 – Matriz de confusão....78
Tabela 5.1 – Métricas de avaliação aplicadas em imagens simuladas quanto às cinco técnicas de segmentação....98
Tabela 5.2 – Métricas de avaliação aplicadas em imagens clínicas quanto às cinco técnicas de segmentação....98
Tabela 5.3 – Descritores mais relevantes....100
Tabela 5.4 – Resultado do treinamento pela rede MLP....103
Tabela 5.5 – Resultado da classificação em imagens simuladas....104
Tabela 5.6 – Resultado da classificação em imagens clínicas....105

SUMÁRIO

RESUMO
ABSTRACT
LISTA DE FIGURAS
LISTA DE TABELAS
1 INTRODUÇÃO 23
1.1 CÂNCER DE MAMA 23
1.2 MOTIVAÇÃO 27
1.3 OBJETIVOS 29
1.4 DISPOSIÇÃO DO TRABALHO 29
2 ULTRASSONOGRAFIA DA MAMA 31
2.1 HISTÓRICO 31
2.2 PRINCÍPIOS FÍSICOS 33
2.3 EQUIPAMENTOS 35
2.3.1 Transdutor 36
2.3.1.1 Matriz Sequencial Linear 38
2.4 MODOS DE IMAGEM 39
2.5 ARTEFATOS 41
2.6 RUÍDO SPECKLE 43
2.7 EMPREGO DO ULTRASSOM NA MAMA 44
2.7.1 Critérios de Classificação 45
3 PROCESSAMENTO DE IMAGENS 51
3.1 REALCE 52
3.1.1 Wiener 52
3.1.2 Equalização 53
3.1.3 Filtro da Mediana 55
3.2 SEGMENTAÇÃO 55
3.2.1 Rede Self-Organizing Map 56
3.3 DESCRITORES DE CARACTERÍSTICAS 59

3.4 CLASSIFICAÇÃO 60
3.4.1 Treinamento 62
4 MATERIAIS E MÉTODOS 63
4.1 BANCO DE IMAGENS 63
4.1.1 Phantoms 67
4.2 PROCESSAMENTO DIGITAL 70
4.2.1 Pré-Processamento 72
4.2.2 Segmentação 72
4.2.3 Pós-Processamento 76
4.3 MÉTODOS DE AVALIAÇÃO 77
4.4 EXTRAÇÃO E SELEÇÃO DE CARACTERÍSTICAS 81
4.5 CLASSIFICAÇÃO 86
5 RESULTADOS E DISCUSSÕES 89
5.1 BANCO DE IMAGENS 89
5.2 PROCESSAMENTO DIGITAL 90
5.3 VALIDAÇÃO 97
5.4 SELEÇÃO DE CARACTERÍSTICAS 99
5.5 CLASSIFICAÇÃO 102
5.6 OBSERVAÇÕES 107
5.7 SOFTWARE 110
6 CONCLUSÕES 115
6.1 DETECÇÃO DAS LESÕES 115
6.2 CARACTERIZAÇÃO DOS ACHADOS ULTRASSONOGRÁFICOS 117
6.3 CONSIDERAÇÕES FINAIS 118
6.4 TRABALHOS FUTUROS 119
REFERÊNCIAS BIBLIOGRÁFICAS 121

1 INTRODUÇÃO

1.1 Câncer de Mama

Costa (2009) define o câncer de mama como crescimento desordenado de células da mama, originando um tumor com capacidade de metástase. Este tipo de câncer se apresenta como um nódulo palpável, de consistência endurecida, quase sempre indolor e fixo.

Esta neoplasia tem sido um dos maiores problemas de saúde pública em todo o mundo, por ser uma das doenças de alto impacto devido à elevada e preocupante incidência, enormes custos sociais, desastrosas consequências físicas e psicológicas, além de altas taxas de mortalidade (COSTA, 2009; FOGAÇA e GARROTE, 2004). É o segundo tipo de câncer mais frequente no mundo e o primeiro entre as mulheres, respondendo, segundo o Instituto Nacional do Câncer (INCA)[1], por 22% de novas incidências a cada ano, e estimando-se para 2012 a ocorrência de 52.680 novos casos no Brasil, ou seja, uma proporção de 52 casos a cada 100.000 mulheres, com cerca de 12.000 mortes a cada ano (MARTINS et al., 2010).

[1] http://www.inca.gov.br/wps/wcm/connect/tiposdecancer/site/home/mama

O diagnóstico e o tratamento precoce do câncer são muito importantes para maior sobrevida das pacientes, possibilitando tratamentos menos agressivos e isto se deve às técnicas de rastreamento (YAP et al., 2006; SHI et al., 2010). Os métodos disponíveis para sua detecção precoce incluem o autoexame, exame clínico realizado por profissional habilitado, mamografia, ultrassonografia, ressonância magnética, punção aspirativa por agulha fina e biópsia (FOGAÇA e GARROTE, 2004; PAULINELLI et al., 2003).

A mamografia continua a ser a modalidade de imagem dominante na avaliação de anormalidades da mama (YU et al., 2011). É o instrumento mais efetivo para o diagnóstico precoce, o qual pode reduzir de 18 a 30% a taxa de mortalidade, permitindo a detecção de 3 a 4 anos antes da manifestação dos sintomas, e possibilitando o diagnóstico de tumores (tanto malignos quanto benignos) com tamanho a partir de 1 milímetro (mm) – o que aumenta em 95% as chances de cura (BORGHESAN et al., 2003).

Embora a mamografia seja reconhecidamente o método mais eficaz no diagnóstico precoce do câncer de mama por apresentar alta sensibilidade (de 85 a 92%), sua especificidade é baixa. Por isso, são altas as chances de um falso-positivo levar a biópsias desnecessárias (LOUVEIRA et al., 2003), que levam a internação hospitalar com necessidade de anestesia; suas complicações em 80% dos casos resultam em alterações benignas, mas podem levar a alterações do parênquima que dificultam a leitura das imagens mamográficas subsequentes (KEMP et al., 2001). A mamografia ainda apresenta o risco da radiação ionizante, e dificuldade adicional na detecção de lesões em mamas densas (LOUVEIRA et al., 2003; YAP et al., 2006). Isso leva à necessidade de averiguar modalidades alternativas para a investigação e identificação do câncer de mama.

Em 1951, Wild e Neal foram os primeiros a propor o uso de imagens de ultrassom no exame da mama (YAP et al., 2006). Desde então, a ultrassonografia vem ganhando popularidade e com os recentes avanços tecnológicos, tem-se mostrado útil na avaliação de anormalidades na mama e tornou-se a principal técnica de triagem adjunta à mamografia (SHI et al., 2010; MASSICH et al., 2010; YU et al., 2011). Tal procedimento ajuda na caracterização de massas encontradas no exame, evitando, assim, a realização de biópsias desnecessárias e eliminando a necessidade de mamografia de controle (PAULINELLI et al., 2003; NASCIMENTO et al., 2009).

As principais indicações e potencialidades da ultrassonografia no exame das mamas são: diferenciar e caracterizar nódulos sólidos e cistos identificados pela mamografia ou pelo exame clínico; orientar procedimentos intervencionistas na mama (guia de aspiração e biópsia em situações específicas); avaliar pacientes jovens, gestantes ou lactantes com alterações clínicas na mama; pesquisar abcessos nas mastites; suplementar a mamografia no rastreamento do câncer em mulheres com mamas radiologicamente densas; analisar implantes mamários; estadiar o câncer de mama; caracterizar assimetrias focais que podem corresponder a nódulos; avaliar a resposta à quimioterapia neoadjuvante (LOUVEIRA et al., 2003; KOPANS, 2008; MASSICH et al., 2010).

Louveira et al. (2003) relatam que a diferenciação entre nódulos sólidos e císticos, no ultrassom, possui eficácia em torno de 95-100%, proporcionando redução de 25-35% no número de biópsias quando utilizada como complemento da mamografia, reduzindo custos adicionais.

Porém, a ultrassonografia não tem valor reconhecido como método isolado no rastreamento do câncer de mama (LOUVEIRA et al., 2003), e uma das razões pela qual não é útil como uma técnica autônoma deve-se a suas limitações na detecção e caracterização de calcificações (não permite a visualização, a menos que tenham diversos milímetros de tamanho ou sejam extremamente numerosas e compactadas), distorções arquiteturais e nódulos localizados em áreas nas quais há o predomínio de tecido adiposo (CHALA e BARROS, 2007).

A detecção de anormalidades em imagens médicas é um procedimento propenso a erros, mesmo para radiologistas qualificados, devido ao grau de subjetividade na definição de fronteiras, sobreposição de características benignas e malignas, além da presença de artefatos, que tende a dificultar o diagnóstico. Buscando minimizar esses erros e ajudar na detecção precoce do câncer de mama, vêm sendo desenvolvidos sistemas computacionais como uma ferramenta de auxílio ao diagnóstico (STAVROS, 2009). Dessa ideia partem duas nomenclaturas, a primeira voltada para a detecção de anormalidades, conhecida como Detecção auxiliada por computador (CADe – *Computer-Aided Detection*), e a segunda relacionada a sua classificação, denominada de Diagnóstico Auxiliado por Computador (CAD/CADx – *Computer-Aided Diagnosis*). Essas abordagens quando aplicadas em conjunto, atuam como uma segunda opinião ao médico na leitura de imagens, melhoria das informações, identificação e caracterização de achados

suspeitos, além de evitar variações entre observadores, possibilitando um diagnóstico mais conclusivo (STAVROS, 2009; DRUKKER et al., 2010; HUANG, 2009).

É importante ressaltar que a decisão final é sempre atribuída ao médico, não havendo, portanto, sua substituição. O esquema computacional é apenas uma ferramenta para a obtenção de informações adicionais, cuja principal função é a melhoria da precisão diagnóstica e consistência da interpretação da imagem mediante a resposta de referência proporcionada pelo computador (DRUKKER et al., 2010; STAVROS, 2009).

Os sistemas CAD, em sua maioria, consistem de quatro etapas: (1) pré-processamento, importante antes da segmentação devido ao ruído; (2) segmentação, em que o objeto é delimitado e separado do tecido de fundo; (3) extração de características, quando são obtidas as características relevantes para a caracterização de um achado; (4) tomada de decisão, em que o classificador apresenta os resultados do diagnóstico com base nas características selecionadas (HUANG, 2009). A Figura 1.1 ilustra o fluxograma proposto por Huang (2009) de um sistema CAD convencional para imagens de ultrassom.

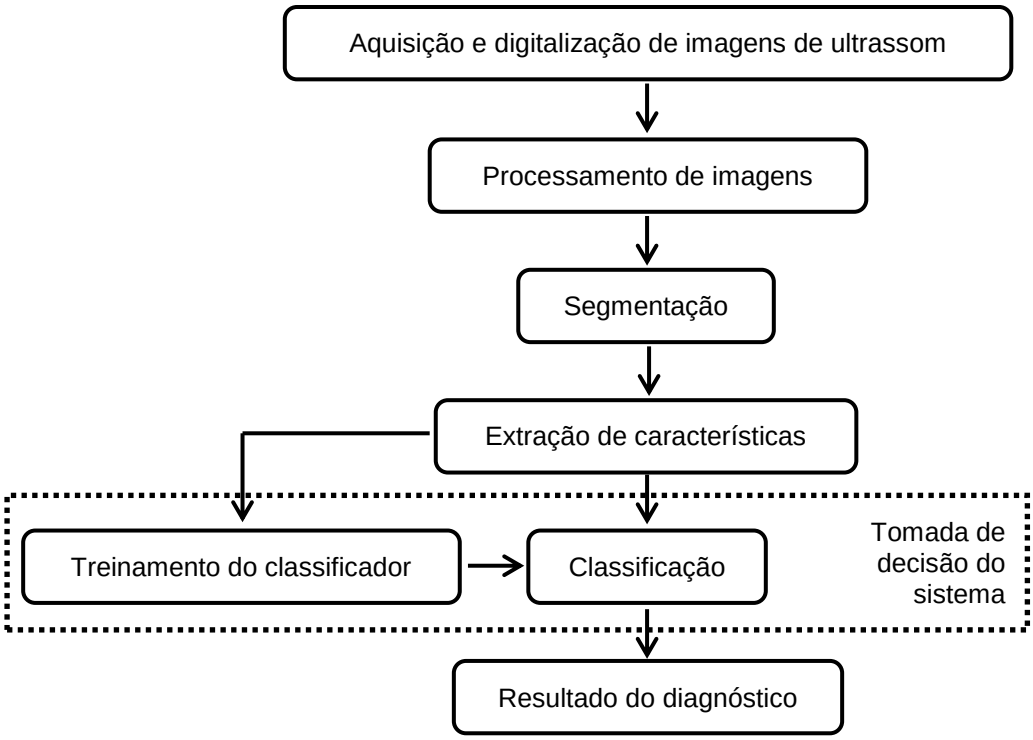

Figura 1.1 – Diagrama em bloco de um sistema geral de Diagnóstico Auxiliado por Computador (CAD) para imagens de ultrassom
(Fonte: HUANG, p. 18, 2009)

Esse tipo de sistema possibilita a redução do número de casos falsos-positivos, pois permite maior compreensão das diferenças morfológicas das anormalidades encontradas na mama (MARTINS et al., 2010). O interesse nessa área vem sendo impulsionado diretamente pelo desenvolvimento tanto em processamento de imagens quanto em inteligência artificial. Contudo, ainda apresenta-se como desafio o desenvolvimento de uma abordagem geral para processar imagens médicas.

Muitas técnicas têm sido exploradas na segmentação de imagens médicas, de um modo geral. No entanto, esta tarefa em ultrassonografias é dificultada devido à existência de ruído *speckle* (CHANG et al., 2005). Nesse intuito, Teng e Chang (2011) propõem a aplicação de diversas técnicas de segmentação a fim de desenvolver uma abordagem geral de processamento em imagens médicas, incluindo imagens obtidas por ressonância magnética, raios X e ultrassom. Os autores apresentam as vantagens e os problemas encontrados quando utilizadas as técnicas de crescimento de região, algoritmos de agrupamento e contorno ativo. Com base em seus testes, os resultados mais efetivos e eficientes foram fornecidos pela rede neural SOM. Assim, decidiu-se investigar a eficiência dos mesmos algoritmos de detecção quando empregados apenas em imagens ultrassonográficas da mama.

A partir da correta delimitação da lesão, é possível realizar a diferenciação de nódulos presentes na imagem. Isso é realizado por meio da extração de características, resolvendo assim, o problema de variabilidade inter e intra-observador. Após a seleção das características mais relevantes, esses valores são fornecidos como entradas para a rede neural artificial (RNA), que por meio de seu algoritmo de decisão, identifica se um nódulo é benigno ou maligno (JOO et al., 2004).

1.2 Motivação

Segundo Gómez et al. (2010) o ultrassom é usado na diferenciação entre tumores benignos e malignos, os quais podem ser caracterizados por suas formas, bordas, disposição do eixo tumoral, características dos ecos internos e comportamento acústico posterior.

A sobreposição de características benignas e malignas na interpretação de imagens de ultrassom torna o processo subjetivo, e tende a dificultar o diagnóstico do especialista, dado por intermédio da inspeção visual. Além disso, a ultrassonografia da mama é um instrumento dependente do operador e tem a presença de artefatos, tais como o *speckle*, que degrada a imagem qualitativamente e dificulta a discriminação de detalhes finos. Para superar esses problemas, os sistemas CAD surgiram com o objetivo de melhorar a análise do radiologista auxiliado por uma caracterização computadorizada e classificação das lesões nas imagens. Dessa maneira, o radiologista pode ter o resultado do CAD como uma segunda opinião e realizar um diagnóstico mais conclusivo (CHANG et al., 2005; GÓMEZ et al. 2010; YAP et al., 2006).

A etapa fundamental nesses sistemas é a delimitação da lesão, em que a mesma é separada do fundo e de outras estruturas. A segmentação desempenha um importante papel na diferenciação entre tumores benignos e malignos, pois é usada para obter uma representação precisa dos limites do tumor (GÓMEZ et al., 2010; YAP et al., 2006). De acordo com Gómez et al. (2010) este procedimento pode ser realizado pela delineação manual do radiologista e, portanto, através da percepção visual da ecotextura e propriedades morfológicas. Por outro lado, a segmentação computadorizada pode eliminar a subjetividade do “desenho” das margens pelo radiologista.

A segmentação é uma tarefa difícil devido à natureza ruidosa da imagem, tornando-a principal razão de imprecisão em muitos sistemas CAD. O processo fica ainda mais comprometido em cenas em que há oclusão parcial de objetos ou sombras, como é o caso da sombra acústica em imagens de ultrassonografia. Uma ampla variedade de técnicas vem sendo proposta para resolver isso; no entanto, o bom funcionamento de um algoritmo de segmentação depende basicamente do pré-processamento da imagem (melhoria e filtragem) e seleção do modelo adequado (GÓMEZ et al., 2010; YAP et al., 2006; SILVA, 2007).

Por isso, de acordo com Yu et al. (2011), é crescente o interesse na determinação de um algoritmo automático de detecção de lesões em imagens de ultrassom assim como o desenvolvimento de um classificador preciso para auxiliar o radiologista no diagnóstico.

1.3 Objetivos

Dado que o grupo do Laboratório de Análise e Processamento de Imagens Médicas e Odontológicas (LAPIMO) vem, há algum tempo, desenvolvendo pesquisas relacionadas à avaliação de qualidade e possíveis melhorias através do processamento digital na elaboração de um esquema CAD para mamografia, o objetivo desse trabalho é contribuir para essa linha, através do desenvolvimento de um *software* que visa avaliar a potencialidade do diagnóstico por decisão computacional na classificação de massas presentes em imagens de ultrassonografia da mama, utilizando técnicas de processamento digital e de redes neurais artificiais.

1.4 Disposição do Trabalho

Além do capítulo apresentado, essa dissertação é composta ainda por mais seis capítulos seguindo a descrição sumária abaixo:

Capítulo 2: Ultrassonografia da mama – relata o desenvolvimento histórico, princípios físicos, conceitos, características dos equipamentos, e a importância da detecção precoce do câncer de mama auxiliada pela técnica de ultrassom.

Capítulo 3: Processamento de Imagens – aborda as técnicas de processamento que buscam a melhoria (realce da imagem), a delimitação do objeto de interesse, os descritores de características e, por fim, os conceitos do classificador neural MLP.

Capítulo 4: Materiais e Métodos – detalha os materiais utilizados e a metodologia empregada no desenvolvimento desta pesquisa.

Capítulo 5: Resultados e Discussões – exibe os resultados obtidos, bem como, a exposição das discussões associadas.

Capítulo 6: Conclusões – conclusões finais do trabalho.

Referências Bibliográficas – literatura consultada e utilizada para o desenvolvimento do projeto.

2 ULTRASSONOGRAFIA DA MAMA

A imagem ultrassônica é uma modalidade diagnóstica não invasiva, portátil, com radiação não ionizante, relativamente barata e que permite a obtenção de imagens em tempo real. O diagnóstico depende da análise computadorizada de ondas de ultrassom refletidas, captadas para a criação de imagens de estruturas internas do corpo (WHO, 2011; WEBB, 2003).

2.1 Histórico

A primeira referência descrita na literatura do uso da ultrassonografia mamária foi em 1951, quando Wild e Neal divulgaram seus estudos, descrevendo as características acústicas, *in vivo*, de dois tumores mamários, um benigno e um maligno (CALAS et al., 2007; MÁTTAR et al., 2009). Já em 1953, Howry publicou imagens bidimensionais de tumores da mama *in vitro* usando pulsos de baixa frequência, produzindo imagens de melhor qualidade diagnóstica (DEMPSEY, 2004).

Dempsey (2004) expõe que a primeira aplicação clínica de ultrassom da mama foi relatada em 1954 por Wild e Reid, sendo que a consideraram apenas como uma técnica para distinguir lesões benignas e malignas, não atuando como detecção e muito menos substituição dos métodos de diagnóstico existentes.

> Nos anos 60, foram realizados inúmeros estudos comparativos de exames mamários ultrassonográficos através da imersão em água, compressão mamária e transdutores de contato que ampliavam a distância transdutor/mama para a identificação do parênquima mamário. Tais aparelhos operavam com frequência de 2 a 2,5 MHz (MÁTTAR et al., 2009).

De acordo com Dempsey (2004), com a apresentação de estudos inicialmente favoráveis, melhorias técnicas começaram a ser feitas nos equipamentos. Em 1969, na Austrália, foi introduzida a imagem em escala de cinza, além da descrição dos princípios da ultrassonografia em escala de cinza para todos os tecidos moles. Enquanto isso nos EUA, a ênfase estava voltada à caracterização, cuja finalidade era a detecção precoce, demonstrando assim, os primeiros estudos no exame de mamas em mulheres assintomáticas de diferentes idades. Foi possível identificar os diferentes elementos estruturais da glândula mamária por padrões ecogênicos, mostrando as diferenças na velocidade do ultrassom em mamas de pacientes com idades diferentes.

A tecnologia digital começou a ser introduzida a partir da década de 1980, quando o equipamento passou a ter sinal digital em vez de analógico, gerando melhorias nos transdutores lineares de alta frequência (5 a 13 Megahertz – MHz) que permitiram uma maior resolução e uma profundidade de imagem mais adequada a uma variação focal de 0,5 a 5 centímetros (cm) (DEMPSEY, 2004; MÁTTAR et al., 2009).

A partir da década de 1990, ocorreram avanços significativos quanto à imagem. Este fator foi decorrente da inserção de sondas mais modernas e pela compensação dos artefatos de espalhamento múltiplo, que reduziu o ruído por meio do estreitamento do feixe principal, permitindo a diferenciação de patologias menores que 0,5 cm, contribuindo, dessa maneira para o diagnóstico e tratamento precoce do câncer de mama. Atualmente, utiliza múltiplos feixes a partir de múltiplos ângulos para produzir uma imagem com aparência suavizada (DEMPSEY, 2004; MÁTTAR et al., 2009).

Na Figura 2.1 podem ser vistas as mudanças ocorridas na qualidade da imagem com a evolução dos equipamentos, tendo por base a demonstração da espinha fetal exposta a diferentes aparelhos de ultrassom encontrados em suas respectivas épocas. Como pode ser observado, houve melhora na resolução espacial e de contraste, redução de ruído de fundo, faixa dinâmica e visualização de campo próximo ou distante.

Figura 2.1 – Modificações na qualidade da imagem dos anos 1985, 1990 e 1995

2.2 Princípios físicos

O som é caracterizado por vibrações (variações de pressão) transmitidas através de um meio, podendo este ser um sólido, líquido ou gás (ao contrário da energia ionizante, como os raios X, que por se tratar de ondas eletromagnéticas, pode também ser transmitida no vácuo). Essas vibrações são ondas de pressão mecânica que transportam energia cinética (WHO, 2011; SANTIN, 2003).

O ouvido humano permite a audição de sons entre 20 a 20.000 Hertz (Hz) de frequência. Esta faixa de valores é denominada de som audível, já valores inferiores a 20 Hz referem-se ao infrassom. O ultrassom é o termo utilizado para descrever sons com frequências além do ouvido humano, ou seja, acima de 20.000 Hz. Frequências de 1 a 30 MHz são típicas para ultrassom diagnóstico (WHO, 2011; MEIRE e FARRANT, 1995; SANTIN, 2003).

O comprimento de onda do ultrassom influencia na resolução das imagens, em que a resolução atingida é maior com comprimento de onda mais curto, remetendo a frequências maiores. No entanto, o uso de altas frequências é limitado por sua grande atenuação no tecido e, portanto, menor é a profundidade de penetração. Por esta razão, em imagens de diagnóstico por ultrassom, as

frequências devem ser altas para garantir a boa resolução da imagem. No entanto, variam de acordo com determinadas faixas para cada aplicação ou partes do corpo, devendo garantir também a correta penetração do sinal no tecido. Frequências de 3 a 5 MHz são aplicadas em áreas abdominais, de 5 a 10 MHz para partes pequenas e superficiais e, por fim, de 10 a 30 MHz para a pele ou os olhos (WHO, 2011; WEBB, 2003).

WHO (2011) atenta que a técnica de ultrassom não é adequada para examinar tecidos contendo ar ou gases (como por exemplo, pulmões saudáveis) ou ainda regiões circum-adjacentes a ossos (tal como, o cérebro), devido ao fato de refletirem quase toda a energia dos pulsos ultrassônicos que chegam ao tecido. Isto ocorre devido a grande impedância acústica entre estruturas de densidade hídrica e ossos ou ar, proporcionando a reflexão total das ondas sonoras. Com base nessa diferença de impedância acústica, torna-se necessário o uso de um agente de acoplamento (gel) para eliminar o ar entre o transdutor e a pele do paciente.

Contudo, ao contrário do ar, o osso absorve mais ultrassom do que partes moles, isso faz com que o exame de ultrassom seja adequado para e avaliar as superfícies dos ossos, já que a energia ultrassônica não chega às áreas localizadas atrás de tais estruturas. Essas regiões posteriores são vistas nas imagens como uma zona de preto, denominada sombra acústica (WHO, 2011).

A impedância acústica nada mais é do que a uma alteração da resistência à passagem do som, é o produto da densidade do material pela velocidade do som no mesmo. Quando um feixe sonoro atravessa uma interface entre dois meios com a mesma impedância acústica, não há reflexão e a onda é transmitida ao segundo meio. Essa diferença é que define a quantidade de reflexão na interface, promovendo sua identificação na imagem. Assim, quanto maior a diferença de impedância acústica entre duas estruturas, maior será a intensidade de reflexão, tornando a região mais facilmente diferençável do meio envolto (VIEIRA, 2005).

A transmissão da onda sonora também está diretamente relacionada com a distância entre os átomos ou moléculas que compõe o meio, portanto a velocidade do som sofrerá variações nos diferentes meios.

A Tabela 2.1 apresenta os valores relativos à densidade, velocidade e impedância acústica de alguns meios relacionados à aplicabilidade clínica do ultrassom (VIEIRA, 2005).

Tabela 2.1 – Valores de densidade, velocidade e impedância acústica em diversos meios clínicos

Meio	Densidade (Kg/m^3)	Velocidade (m/s)	Módulo de Impedância Acústica ($Kg/m^2.s$)
Ar	1,2	330	$0{,}0004*10^6$
Água (20°C)	1000	1480	$1{,}48*10^6$
Gordura	1054	1475	$1{,}38*10^6$
Mama	1020	1510	$1{,}54*10^6$
Fígado	1060	1555	$1{,}65*10^6$
Sangue	1057	1575	$1{,}62*10^6$
Músculo	1080	1580	$1{,}70*10^6$
Osso do Crânio	1786	6420	$6{,}00*10^6$

Como podemos observar na tabela acima, a velocidade média de propagação do som em tecidos de partes moles é de 1540 metros por segundo (m/s).

2.3 Equipamentos

De acordo com Webb (2003), a instrumentação para a geração de imagens ultrassônicas consiste de um transdutor ou de único cristal ou, mais comumente, uma matriz de cristais; detectores eletrônicos, que incluem módulos para ganhar tempo de compensação e formação de feixe; e computadores para processar dados, exibir imagens e armazenar os dados. A Figura 2.2 apresenta um aparelho de ultrassom portátil.

Figura 2.2 – Aparelho portátil de ultrassom (Medisson)

Jan (2006) descreve que o uso do ultrassom para diagnósticos é feito a partir de um transdutor que emite pulsos (o sinal produzido é dado pela conversão da energia mecânica em tensão elétrica, bem como seu inverso) e esse transdutor atua, geralmente, como emissor e receptor de energia ultrassônica. Os detectores eletrônicos permitem a alteração do tamanho do feixe a ser formado e ganho de tempo de compensação. O computador detecta e processa os sinais recebidos (ondas refletidas e espalhadas) e os converte em imagem. A partir daí, essas imagens podem ser exibidas ou ainda armazenadas.

2.3.1 Transdutor

De acordo com WHO (2011) o transdutor é o componente mais importante da máquina de ultrassom, é através dele que são emitidas e recebidas as vibrações mecânicas. É constituído de um material piezoelétrico (como por exemplo, a cerâmica de titanato zirconato de chumbo). Esses são materiais diferenciais por permitir alterações em sua espessura. A Figura 2.3 exibe a estrutura interna e os componentes básicos de um transdutor.

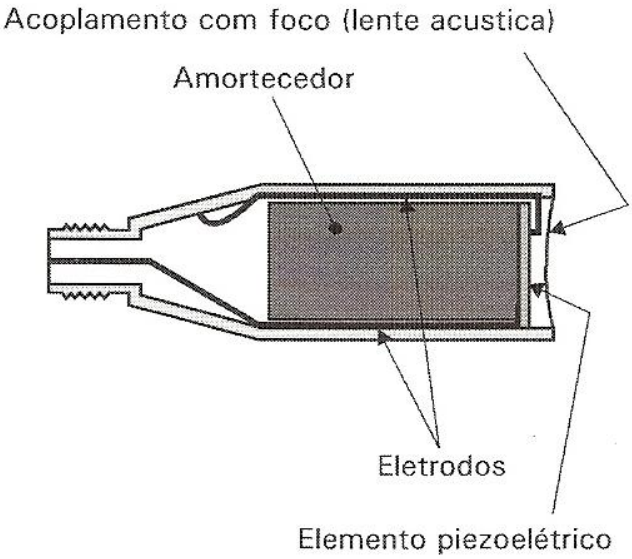

Figura 2.3 – Estrutura interna de um transdutor

Esses cristais piezoelétricos são capazes de converter pressão mecânica em tensão elétrica, fenômeno denominado de efeito piezoelétrico. Por outro lado, o

efeito piezoelétrico inverso ou recíproco ocorre quando é aplicada tensão elétrica alternada aos lados opostos do material, o que resulta na expansão de sua superfície e induz a formação de oscilações que são transmitidas como ondas de ultrassom para o meio circundante.

A espessura (geralmente de 0,1 a 1,0 mm) dos cristais determina a frequência do ultrassom. Na maioria das aplicações de diagnóstico, o ultrassom é emitido em pulsos extremamente curtos. Quando não está emitindo um pulso (99% do tempo), o mesmo cristal piezelétrico pode atuar como um receptor.

Desse modo, a sonda ou transdutor emite um pulso ultrassônico de ondas curtas que se propaga no meio (tecido, por exemplo). Ao tocar um objeto de propriedades diferentes do meio (ou seja, um órgão de impedância acústica diferente), a onda é refletida, refratada ou dispersa, dependendo do tamanho do objeto e do caráter da interface de impedância. Uma parte da energia da onda retorna para a sonda, onde é detectado como um pulso (JAN, 2006). Usando o tempo de atraso, que é medido pelo tempo entre a emissão de um pulso e a recepção do seu eco, pode-se estimar a profundidade percorrida no tecido (JAN, 2006; WHO, 2011). A Figura 2.4 ilustra o processo de emissão de um pulso ultrassônico, que atravessa o tecido de diferentes impedâncias acústicas, e o sinal recebido, dado por sua amplitude e o tempo que o mesmo leva para atravessar o tecido.

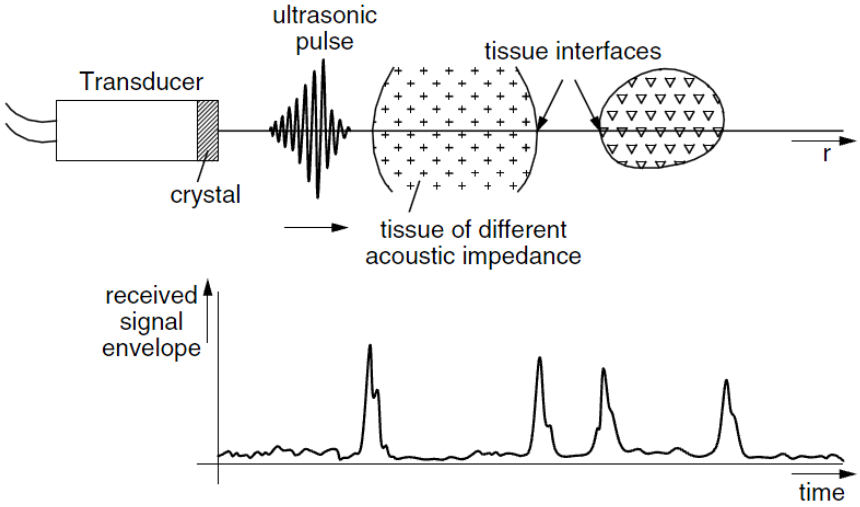

Figura 2.4 – Medição de uma linha básica de ultrassom
(Fonte: Jan, p. 286, 2006)

A forma e, especialmente, o diâmetro do feixe influenciam fortemente a resolução lateral e, assim, a qualidade da imagem. A zona de foco é a área de melhor resolução e deve sempre ser posicionada para coincidir com a região de interesse. Esta é outra razão para a utilização de diferentes transdutores para examinar diferentes regiões do corpo (WHO, 2011). A Figura 2.5 apresenta diferentes modelos de transdutores, em que cada um possui uma aplicação específica.

Figura 2.5 – Alguns exemplos dos diferentes tipos de transdutores

2.3.1.1 Matriz Sequencial Linear

Webb (2003) expõe que uma matriz sequencial linear consiste de um grande número de cristais piezelétricos retangulares, cada um com largura da ordem do comprimento de onda do ultrassom. Cada cristal é físico e eletricamente isolado de seus vizinhos.

Como mostrado na Figura 2.6, uma frente de onda planar pode ser produzida enviando um pulso de tensão para um número de elementos, neste caso os três primeiros. A largura do feixe ultrassônico é determinada pelo número de elementos que são excitados. Após o eco retroespalhado ser recebido, um segundo pulso de tensão é aplicado no segundo e terceiro elemento, produzindo uma frente de onda planar com um ponto focal sendo deslocado lateralmente com relação à primeira

linha. A excitação sequencial desses três elementos separados continua até que todos os grupos tenham sido excitados. Então o processo pode ser repetido usando excitação simultânea de um mesmo número de elementos, neste caso quatro, que produz pontos focais em locais entre aqueles adquiridos anteriormente (WEBB, 2003).

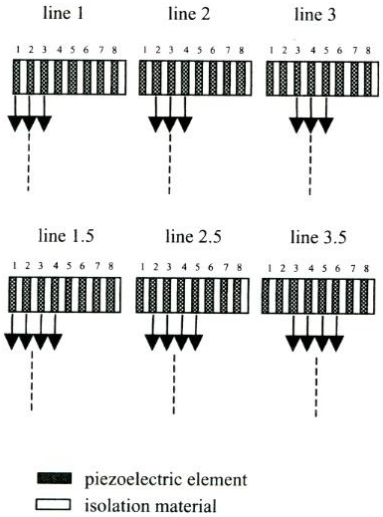

Figura 2.6 – Processo de formação de imagem utilizando um transdutor de matriz sequencial linear (Fonte: WEBB, p.126, 2003)

2.4 Modos de Imagem

Webb (2003) apresenta três modos de varredura básicos de diagnóstico da imagem anatômica utilizando ultrassom: modo-A, modo-B e modo-M. Dependendo da aplicação clínica em questão, um ou mais desses modos podem ser utilizados.

O modo-A ou modulação de amplitude refere-se a uma técnica de exame por uma varredura unidimensional, em que é utilizado um transdutor com um único cristal. Os ecos são mostrados na tela em forma de um gráfico, exibindo o tempo (distância) dos picos proporcional à intensidade (amplitude) de cada sinal. Não é muito utilizado atualmente por transmitir informação limitada, como a medição de distâncias. Na medicina, é utilizado na oftalmologia para determinar a distância relativa entre diferentes regiões dos olhos, por exemplo, detecção do distanciamento da córnea (WEBB, 2003; WHO, 2011; SANTIN, 2003). A Figura 2.7 expõe um exemplo de como o sinal é recebido pelo transdutor e como é exibido ao usuário.

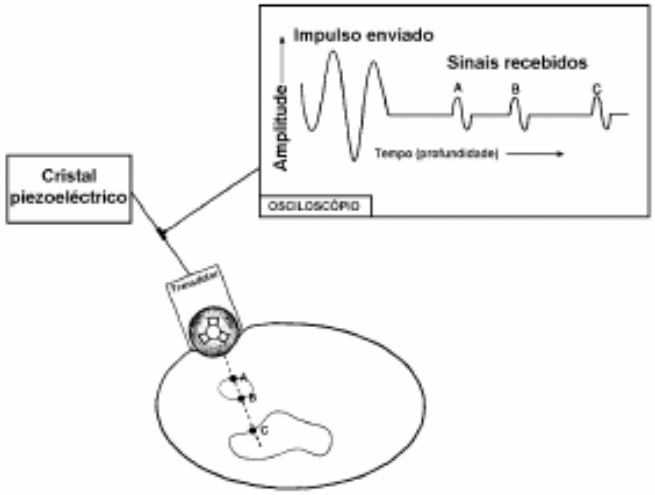

Figura 2.7 – Representação da obtenção de imagens na varredura modo-A

Já o modo-B (ou modo brilho) de varredura, é uma técnica semelhante, mas os ecos são exibidos como pontos de brilho em diferentes tons de cinza correspondendo à intensidade (amplitude) de cada sinal (quanto maior a amplitude do ultrassom refletido, mais branca será a linha correspondente), isto produz uma imagem bidimensional, através do corte transversal do tecido. Cada linha da imagem consiste de uma varredura modo-A, com o brilho do sinal sendo proporcional a amplitude do eco retroespalhado. A varredura modo-B pode ser usada para estudar estruturas fixas e móveis, tais como o coração (WHO, 2011; WEBB, 2003).

Estas imagens podem ser estáticas ou dinâmicas, essa última, o movimento pode ser representado em tempo real. A Figura 2.8 ilustra o processo de obtenção de imagem pela varredura modo-B.

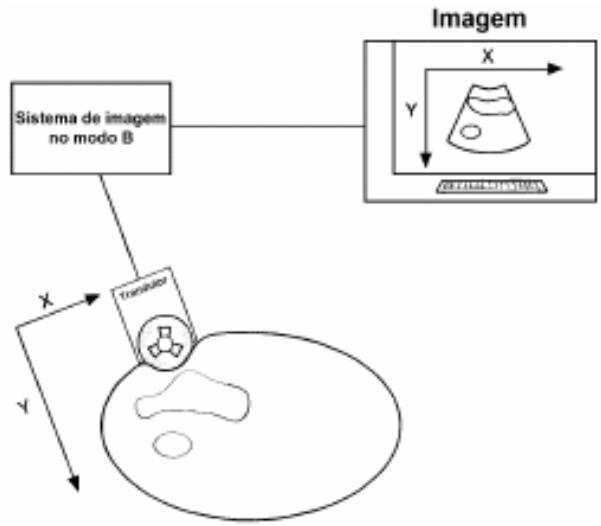

Figura 2.8 – Processo de obtenção de imagem pela varredura modo-B

Por fim, temos o modo-M ou modo-TM (movimento no tempo) que é usado para analisar estruturas móveis, tais como válvulas cardíacas, fornecendo informação sobre o movimento do tecido dentro do corpo. Os ecos gerados por um transdutor estacionário unidimensional modo-B são registrados continuamente ao longo do tempo, ou pode ser traçada uma linha sobre a imagem modo-B, por intermédio do cursor presente no computador (WHO, 2011; WEBB, 2003). A Figura 2.9 exibe uma imagem modo-B em que é traçada uma linha, e logo abaixo é apresentado o movimento (modo-M de varredura) do órgão em questão.

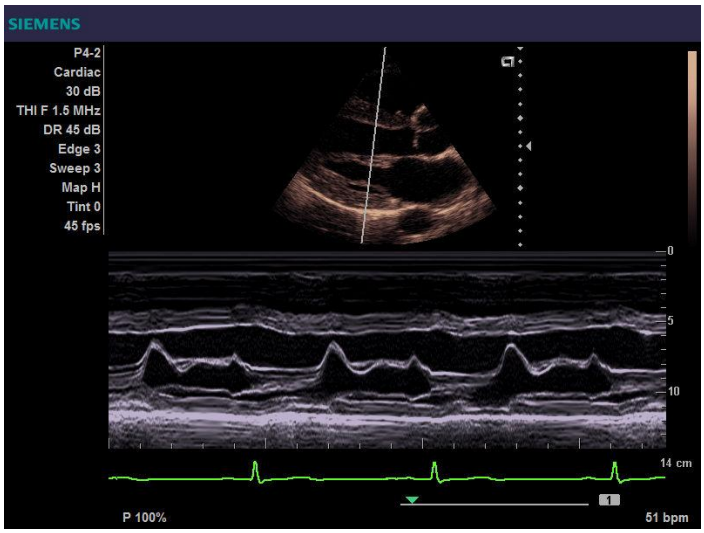

Figura 2.9 – Imagem modo-M

2.5 Artefatos

Para WHO (2011) artefatos são características de uma imagem de ultrassom que não correspondem a estruturas reais, ou seja, elas não representam uma interface acústica real em relação à forma, intensidade ou localização. Dessa maneira, Webb (2003) relata que os artefatos devem ser reconhecidos para evitar erros de interpretação da imagem, ocasionados pela imprecisão na representação física do tecido. Os efeitos a serem considerados como artefatos incluem reverberação, reforço ou sombreamento acústico e refração.

Reverberações ocorrem se há um forte refletor perto da superfície do transdutor. Múltiplas reflexões ocorrem entre a superfície do transdutor e o refletor, e essas reflexões aparecem como uma série de linhas repetidas na imagem, como

mostrada na Figura 2.10. Esses artefatos são relativamente simples de detectar devido à natureza equidistante das linhas. Tipicamente, eles ocorrem quando o ultrassom interage com osso ou ar (WEBB, 2003).

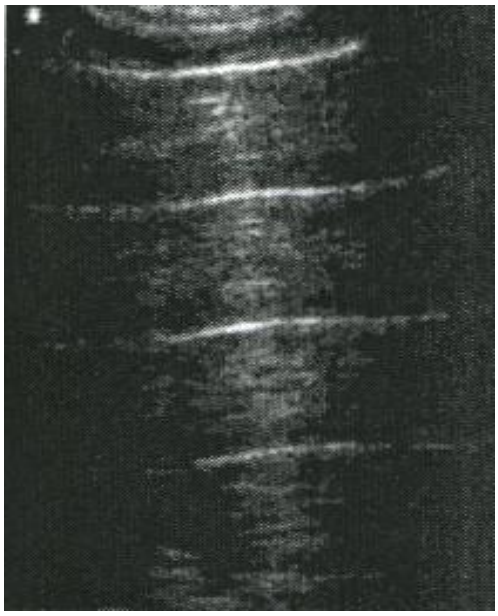

Figura 2.10 – Imagem ultrassônica de um pulmão mostrando fortes artefatos de reverberação (Fonte: WEBB, p. 133, 2003)

O sombreamento acústico ocorre quando um refletor muito forte, tal como o limite de um gás/tecido, ou um meio altamente atenuante “sombreia” um órgão mais profundo. O sombreamento acústico resulta em uma área escura, como apresentado na Figura 2.11. O fenômeno oposto, conhecido como reforço acústico ocorre quando uma região de baixa atenuação é apresentada dentro de outro meio homogêneo. Exemplos clínicos de tecidos com baixo coeficiente de atenuação são cistos, vasos e órgãos cheios de líquido, como a vesícula biliar. As áreas atrás de tais tecidos têm maior intensidade que a esperada, que é uma ferramenta útil para o diagnóstico na diferenciação entre cistos (cheios de líquido) e massa sólida (WEBB, 2003).

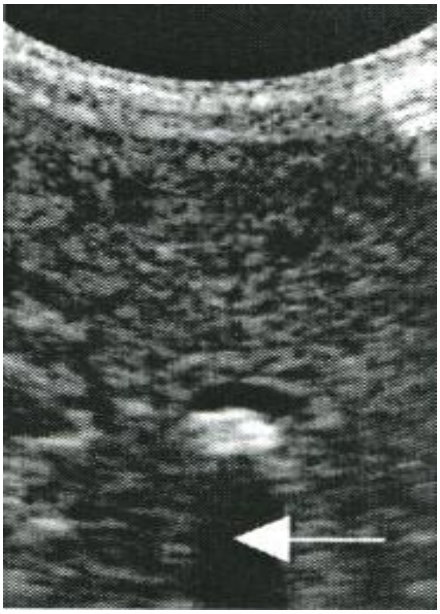

Figura 2.11 – Imagem ultrassônica com sombreamento acústico
(Fonte: Webb, p. 133, 2003)

A refração ocorre nos limites acústicos, e nada mais é do que a mudança de direção que um feixe sofre quando passa de um meio para outro (WHO, 2011). Esse efeito é mais problemático nos limites entre ossos e tecidos moles, onde ocorre grande reflexão (WEBB, 2003).

2.6 Ruído Speckle

As imagens de ultrassom sofrem com o ruído *speckle*, que nada mais é que um ruído multiplicativo que se dá em função de interferências destrutivas entre duas ou mais reflexões acústicas que se sobrepõem (YAP et al., 2006). Esse problema ocorre pela característica do sensor, pois a amplitude e fase final do sinal de retorno são resultantes de uma soma vetorial (coerente) dos sinais de retorno de vários difusores contidos em cada célula de resolução, como ilustrado na Figura 2.12.

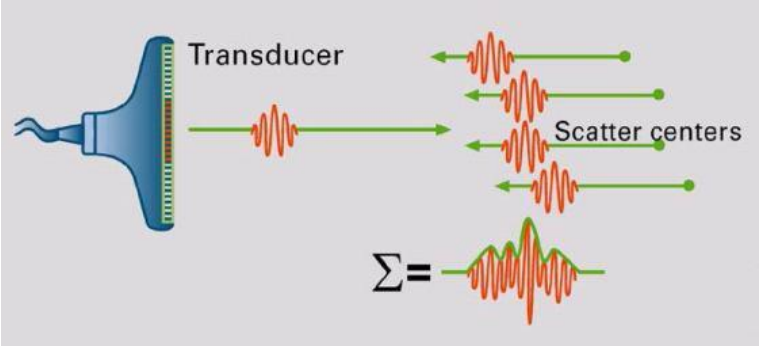

Figura 2.12 – Formação do *speckle*

Dessa forma, as ondas sonoras não são apenas refletidas, boa parte do som é disperso pelos tecidos e, portanto, não retorna diretamente para o transdutor, mas reflete em outras direções. Os tecidos também absorvem o som, convertendo-o em calor. Como o feixe de som é disperso e atenuado enquanto penetra nos tecidos, a intensidade do sinal que retorna para o transdutor se enfraquece rapidamente com o aumento da profundidade da penetração (KOPANS, 2008).

Para Webb (2003) esse efeito é um padrão representado por mudanças bruscas em brilhantes e escuros, gerando uma textura com aparência granular ao que devia apresentar-se como tecido homogêneo. Isso reduz significativamente o contraste nas imagens e a distinção entre sutis graduações em fronteiras de estruturas presentes nos tecidos.

2.7 Emprego do Ultrassom na Mama

Meire e Farrant (1995) relatam que uma série de *scanners* dedicados a ultrassom da mama tem-se desenvolvido ao longo dos últimos 15 anos. Exames modernos de ultrassom da mama são realizados por contato em tempo real de varredura, com um transdutor de disposição reta linear de 5 - 7,5 MHz.

Em imagem da mama, o ultrassom é utilizado em conjunto com a técnica primária de mamografia, no diagnóstico do câncer. A técnica não pode ser usada como um procedimento de triagem por não atender a algumas patologias na mama, e é utilizada apenas para esclarecer ainda mais sobre a massa detectada na mamografia ou exame clínico (MEIRE e FARRANT, 2005; WEBB, 2003).

> As principais indicações da ultrassonografia nas mamas são: diferenciar e caracterizar nódulos sólidos e cistos identificados pela mamografia ou pelo exame clínico; orientar procedimentos intervencionistas na mama; avaliar pacientes jovens, gestantes ou lactantes com alterações clínicas na mama; pesquisar abscessos nas mastites; avaliar nódulos palpáveis em mamas radiologicamente densas; analisar implantes mamários; estadiar, locorregionalmente, o câncer de mama; caracterizar assimetrias focais que podem corresponder a nódulos; avaliar a resposta à quimioterapia neoadjuvante; suplementar a mamografia no rastreamento do câncer de mama em mulheres com mamas radiologicamente densas (CHALA e BARROS, 2007).

> Apesar das limitações, afirma-se que um ultrassonografista experiente pode alcançar uma taxa de sucesso de aproximadamente 95% na correta diferenciação entre lesões benignas e malignas na mama. Quando a técnica é combinada com a mamografia por raios X convencional a taxa diagnóstico correto sobe para aproximadamente 99% (MEIRE e FARRANT, 1995).

2.7.1 Critérios de Classificação

O sistema de linguagem padronizada BI-RADS (*Breast Imaging Reporting and Data System*), introduzido pelo Colégio Americano de Radiologia (ACR – *American College of Radiology*), propôs, em 2003, a primeira edição do sistema para ultrassom mamário. Tal linguagem visa descrever e classificar os achados ultrassonográficos (MÁTTAR et al., 2009; PAULINELLI et al., 2007).

“O sistema BI-RADS começa descrevendo a composição mamária (ecotextura do parênquima), variando desde mais gordurosa, até mais fribroglandular” (MÁTTAR et al., 2009).

Após a caracterização da ecotextura mamária, são considerados os possíveis achados, tais como, nódulos, calcificações, casos especiais e vascularização (MÁTTAR et al., 2009). Para a avaliação e classificação dos nódulos seguimos os seguintes critérios: forma, orientação do nódulo em relação à pele, contornos, limites ou margens, ecogenicidade e ecos posteriores (CALAS et al., 2007; PAULINELLI et al., 2007; NASCIMENTO, 2009).

A forma pode ser definida (arredondada, ovóide ou alongada) ou indefinida, como apresentado na Figura 2.13.

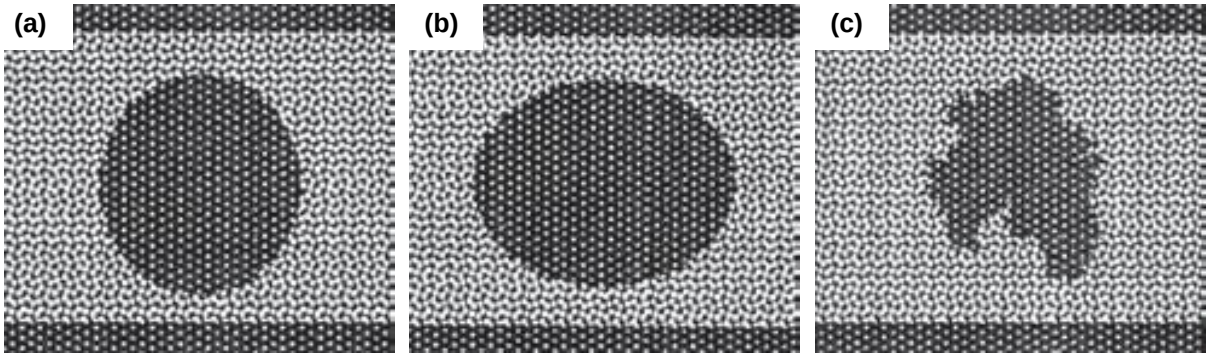

Figura 2.13 – (a) Forma definida redonda e (b) ovóide; (c) forma indefinida

Já o contorno ou margem (Figura 2.14) pode ser regular, parcialmente regular (aspecto bocelado ou também conhecido como macrolobulado) ou irregular (aspecto angular, microlobulado, espiculado ou indistinto).

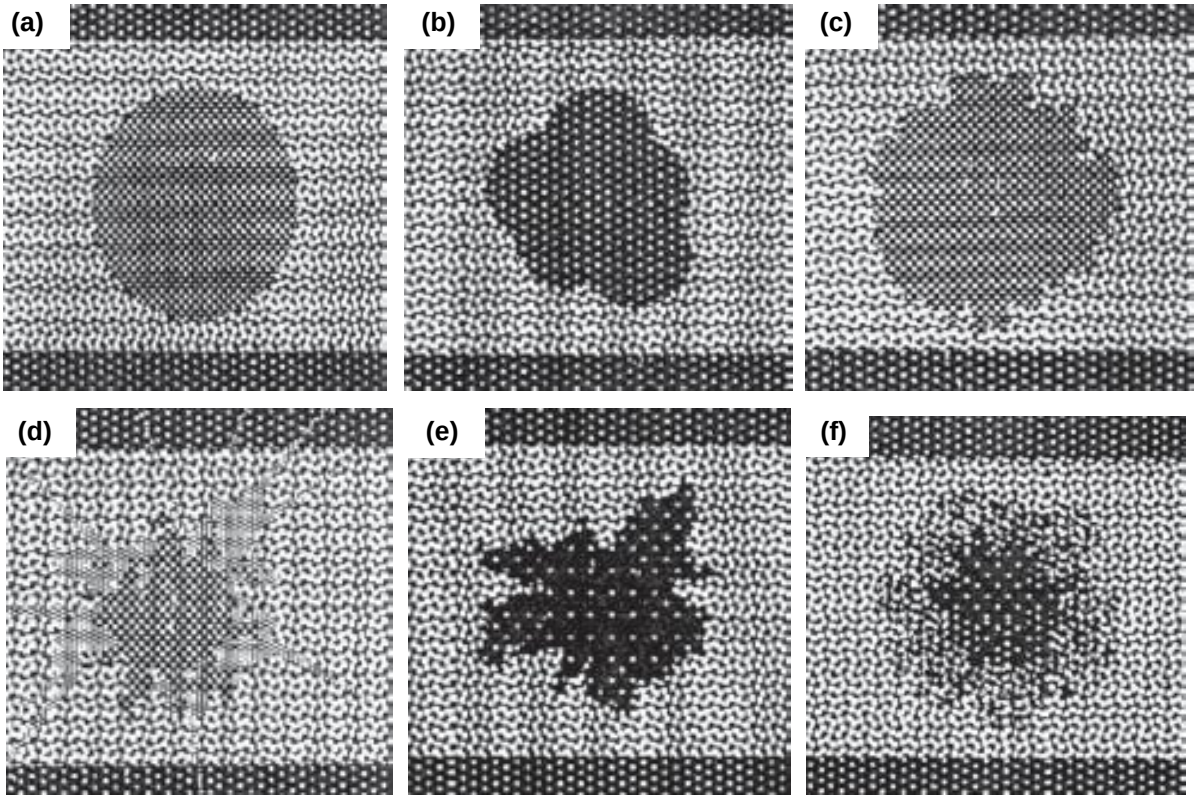

Figura 2.14 – Contorno: (a) regular, (b) macrolobulado; Contorno irregular, podendo ser de aspecto (c) microlobulado, (d) espiculado, (e) angular e (f) indistinto

A ecogenicidade dá-se pela comparação das imagens com o tecido fibroadiposo circunjacente, podendo ser anecóica (ocorre a transmissão completa do som sem reflexão – ecos, originando uma imagem negra), hipoecóica (imagens que ocorreram reflexões esparsas ou transmissão intermediária, apresentando uma região cinza), isoecóica (estruturas que possuem ecogenicidade semelhante ao

fundo) e hiperecóica (significa que ocorreram muitas reflexões, dando origem a uma imagem branca). Os exemplos das diferentes ecogenicidades podem ser visualizados pela Figura 2.15.

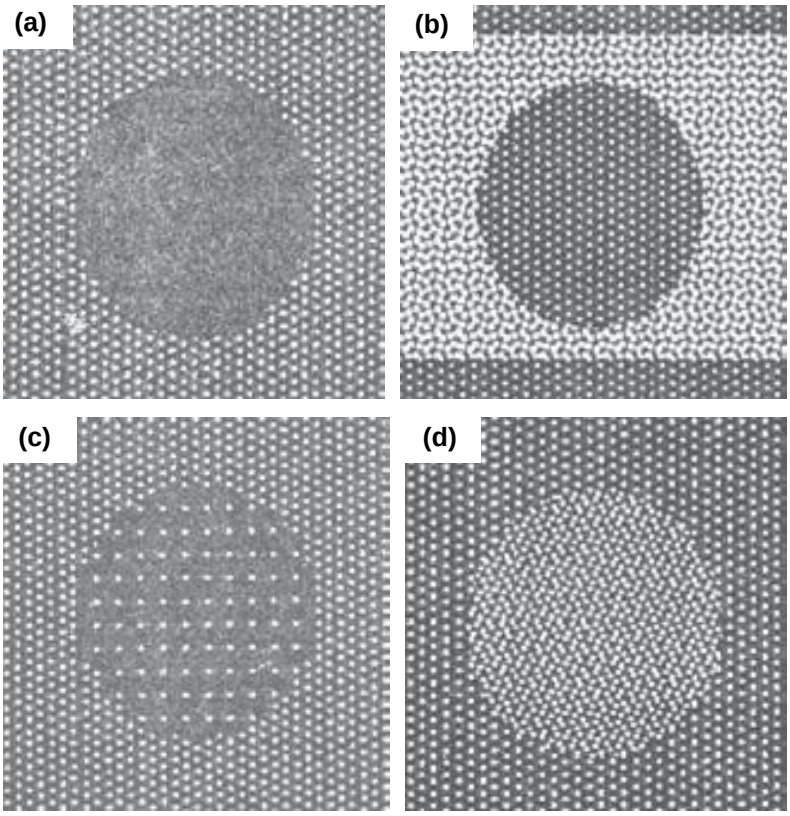

Figura 2.15 – Ecogenicidade: (a) anecóica, (b) hipoecóica, (c) isoecóica e (d) hiperecóica

Em relação à ecotransmissão (Figura 2.16), pode ser considerada como ausente, apresentar reforço acústico posterior ou sombra posterior.

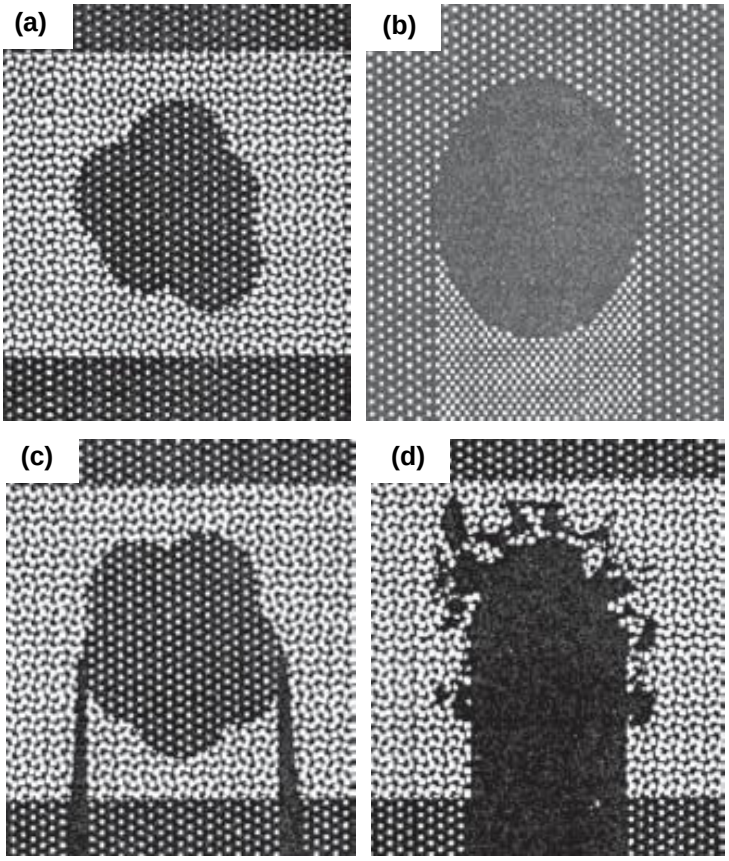

Figura 2.16 – Ecotransmissão: (a) ausente, (b) reforço acústico, (c) sombra acústica bilateral e (d) sombreamento acústico

E por fim, a classificação quanto à orientação é definida apenas como vertical e horizontal, cujos exemplos estão apresentados pela Figura 2.17.

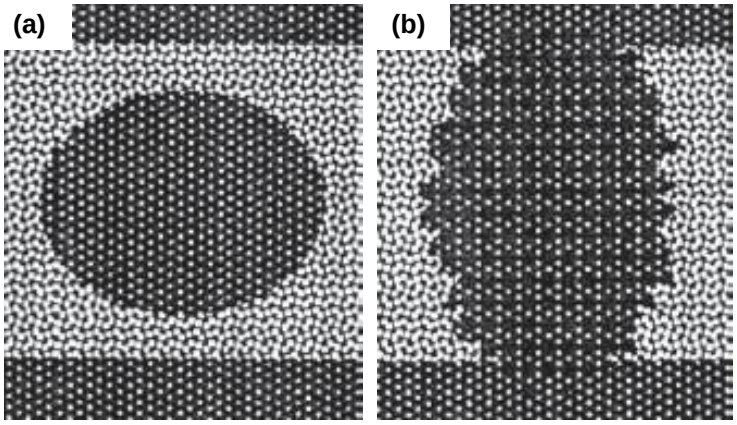

Figura 2.17 – Orientação: (a) horizontal e (b) vertical

Para a avaliação das propriedades mencionadas por meios computacionais, tornou-se necessário o agrupamento de certas características, para que estas pudessem ser avaliadas na forma binária (CALAS et al., 2007). Com base nas cinco

características apresentadas acima, Stavros então propõe os critérios de benignidade e malignidade agrupando tais características, os quais estão descritos na Tabela 2.2 (LOUVEIRA et al., 2003; MÁTTAR et al., 2009).

Tabela 2.2 – Critérios de benignidade e malignidade na classificação dos nódulos mamários

Classificação	Critérios de Benignidade	Critérios de Malignidade
Forma	Forma redonda ou Oval	Forma Irregular
Eixo Tumoral	Orientação Longitudinal	Orientação Irregular
Margens	Contornos Circunscritos	Contornos Indistintos, Espiculados, Microlobulados ou Angulados
Característica Acústica Posterior	Reforço Acústico	Sombra Acústica
Ecogenicidade	Anecóico, Hiperecogênico ou Isoecogênico	Complexo ou Hipoecogênico

3 PROCESSAMENTO DE IMAGENS

Silva (2003) revela que o processamento de imagens consiste no emprego de técnicas que tentam obter informações específicas para cada aplicação, tais como, extração de textura, detecção de bordas, delimitação da área, além de possibilitar a compressão e reconstrução da imagem.

As técnicas de processamento de imagens podem ser divididas em dois estágios, sendo eles, o processamento digital e a análise. O processamento digital consiste em técnicas que procuram melhorar a qualidade das imagens para a interpretação humana ou de máquina. Já a análise, retira as informações necessárias para determinada aplicação, sendo que a entrada é uma imagem enquanto a saída é sua descrição, podendo também ser entendido como redução de dados, mantendo o conteúdo da informação relevante para uma dada aplicação (GONZALEZ e WOODS, 2010; MARQUES FILHO e VIEIRA NETO, 1999).

3.1 Realce

De acordo com Marques Filho e Vieira Neto (1999) o principal objetivo das técnicas de realce em imagens é processá-la, de modo que, a resultante seja mais adequada que a original. Contudo, a interpretação do melhor resultado é subjetiva e não há uma teoria geral, pois depende da aplicação em que é empregada e do conhecimento prévio do observador.

Esse tipo de processamento é considerado de baixo nível, devido o envolvimento de operações primitivas, tais como, pré-processamento para redução de ruído, aumento de contraste e suavização da imagem. Tal procedimento não aumenta a quantidade de informação, e sim facilita a percepção de determinados detalhes, ocasionada pela melhoria na qualidade visual.

O baixo contraste pode advir de vários motivos, como por exemplo, defeito no sensor, o que pode provocar a minimização no intervalo da escala de cinza, tornando sua visualização ou interpretação comprometida (ALVES, 2010).

Chang et al. (2005) expõem que há vários requisitos fundamentais em métodos de filtragem para minimização de ruído em imagens médicas que devem ser levados em consideração. Primeiro, a técnica empregada não pode proporcionar perda de informações importantes tanto em detalhes referentes à borda do objeto quanto relativos à suas estruturas. Segundo, deve remover eficientemente o ruído em regiões homogêneas, e terceiro, aumentar a definição morfológica pelas descontinuidades de nitidez.

3.1.1 Wiener

O filtro de *wiener* pode reduzir o ruído específico utilizando a suavização ou técnicas de melhoria de alta frequência. É o melhor filtro baseado no erro quadrático médio (ZHU et al., 2009a). Atua como um filtro passa-baixa visando reduzir o ruído aditivo baseando-se em estatísticas estimadas a partir da vizinhança local de cada *pixel* para estimar a média local e o desvio padrão (HUANG e CHEN, 2004).

3.1.2 Equalização

A equalização objetiva destacar o brilho da imagem, de forma a produzir a máxima variância entre os níveis de cinza, obtendo um aumento/alargamento do contraste dos objetos na cena, realçando as diferenças de tonalidades e possibilitando melhor discernimento das informações. Na imagem original, os níveis de cinza estão concentrados nas baixas intensidades, já quando é empregada a equalização ocorre uma distribuição mais uniforme (redistribuição) em sua intensidade (o número percentual de *pixels* de qualquer nível de cinza é praticamente o mesmo), isto produz uma imagem mais plana, em que todos os níveis de cinza são equiprováveis (SOUZA e CORREA, 2007; MARQUES FILHO e VIEIRA NETO, 1999; NIXON e AGUADO, 2008; BANKMAN, 2009).

Através da visualização do histograma de uma imagem obtemos uma indicação de sua qualidade referente ao nível de contraste e seu brilho médio (se a imagem é predominantemente clara ou escura). Nas barras verticais justapostas apresentadas no histograma, a base de cada uma delas corresponde ao intervalo de classe e a sua altura à respectiva frequência. Na Figura 3.1 podemos destacar, por meio de seu histograma, uma representação de uma imagem escura e com baixo contraste.

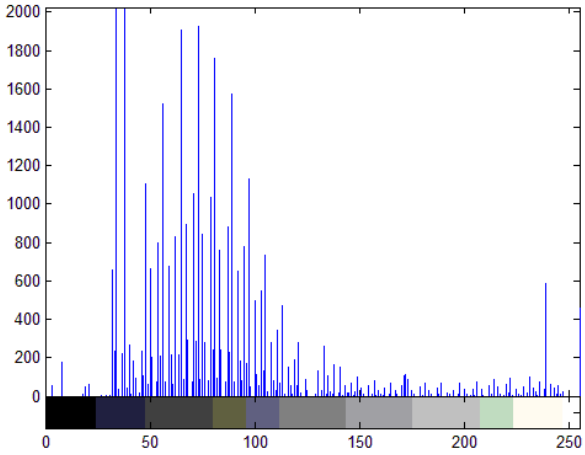

Figura 3.1 – Histograma da imagem

O histograma de uma imagem com bom contraste possui barras dispersas ao longo de todo o intervalo escalar. A Figura 3.2 apresenta o histograma da mesma imagem após sua equalização, exibindo a redistribuição nos níveis de cinza, com a alocação dos níveis de cinza por todo o eixo.

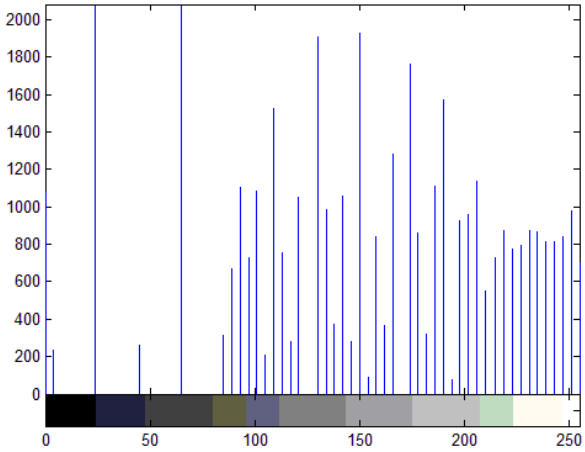

Figura 3.2 – Histograma da imagem equalizada

O alargamento de contraste é dado pela probabilidade de ocorrência de certo nível de intensidade em uma imagem digital. Desta maneira, é escolhida arbitrariamente uma quantidade de k níveis ($k = 0,1,2,3,...,L-1$), cujo valor de L representa o número de níveis de intensidade possíveis na imagem. Com base na equação 3.1, os níveis de cinza são acumulados, visando uma saída uniforme. Portanto, o número de pontos por nível na imagem de saída é a razão entre o número total de pontos para a faixa de níveis na imagem de saída (NIXON e AGUADO, 2008; GONZALEZ e WOODS, 2010).

$$p_r(r_k) = \frac{n_k}{MN} \qquad 3.1$$

em que, MN é o número total de *pixels* da imagem, n_k é o número de *pixels* com intensidade r_k.

Assim, a imagem de saída é obtida mapeando cada *pixel* da imagem de entrada com intensidade r_k em um *pixel* correspondente com nível s_k na imagem de saída, utilizando a equação 3.2 (GONZALEZ e WOODS, 2010).

$$s_k = T(r_k) = (L-1)\sum_{j=0}^{k} p_r(r_j) = \frac{(L-1)}{MN}\sum_{j=0}^{k} n_j \qquad 3.2$$

3.1.3 Filtro da Mediana

Buscando diminuir o ruído ao invés de borrar, uma abordagem alternativa consiste no uso do filtro da mediana (GONZALEZ e WOODS, 2010; MARQUES FILHO e VIEIRA NETO, 1999), em que as distorções são detectadas e esses *pixels* tendem a ser eliminados. Dessa forma, o filtro da mediana elimina o ruído sem desfocar significativamente a imagem (JÄHNE, 2002).

A mediana nada mais é que um modelo estatístico, apresentado por uma janela deslizante, abrangendo um número ímpar de *pixels*, cujos valores, presentes nessa janela, são organizados de forma ascendente em um vetor. O ponto de interesse resultante é dado pelo valor central do vetor ordenado (PRATT, 2007; NIXON e AGUADO, 2008; JÄHNE, 2002).

De acordo com Nixon e Aguado (2008) esse filtro baseia-se no fato de que se um ponto for um ruído, ao colocar em ordem crescente o ponto central e sua vizinhança, o ruído tende a ficar no extremo da ordem disposta, visto que, ao aplicar o filtro, este é substituído pelo valor mediano do conjunto de *pixels* da matriz. O operador mediano tem a vantagem de reter as bordas (os limites e formas em imagens), enquanto suprime o ruído.

Pratt (2007) diz que há várias estratégias para a aplicação do filtro da mediana para supressão do ruído. Um método seria tentar o filtro da mediana com uma janela de tamanho 3, se não houver perda significativa, o comprimento da janela pode ser aumentado para 5 (mediana da imagem original). O processo deve ser encerrado quando o filtro da mediana começa a tornar-se prejudicial à imagem, não podendo haver perdas relativas às bordas ou a estrutura do objeto de interesse.

3.2 Segmentação

A segmentação consiste no processo de identificação de regiões ou objetos de interesse que possuam características semelhantes (como brilho, cor ou textura) em uma imagem ou ainda a delimitação de regiões descontínuas (GONZALEZ e WOODS, 2010; TENG e CHANG, 2011).

É importante lembrar que o uso da segmentação não tem por finalidade reconhecer os segmentos individuais ou suas relações entre si, sua tarefa é

particionar uma imagem em regiões de *pixels* relevantes para uma dada aplicação, ou seja, dividi-la em unidades significativas dos objetos de interesse, mas essa subdivisão depende do problema que se pretende resolver. A segmentação deve parar quando os objetos forem detectados (PRATT, 2007; MARQUES FILHO e VIEIRA NETO, 1999; GONZALEZ e WOODS, 2010; JÄHNE, 2002).

3.2.1 Rede Self-Organizing Map

As redes de mapas auto-organizáveis (*Self-Organizing Map* – SOM) foram desenvolvidas por Treuvo Kohonen em 1980, por isso, também são chamadas de redes de Kohonen. A rede leva esse nome por ter uma estrutura topológica, porém não é fixa e pode assumir diversos formatos, embora o quadrado seja o mais comum. A definição do formato mais adequado depende do problema atacado e da distribuição de seus dados. Geralmente o formato da vizinhança é definido por tentativa e erro (BRAGA et al., 2007).

Cada unidade da camada de entrada está totalmente conectada com todos os neurônios da grade. Esta estrutura pode ser vista através da representação presente na Figura 3.3.

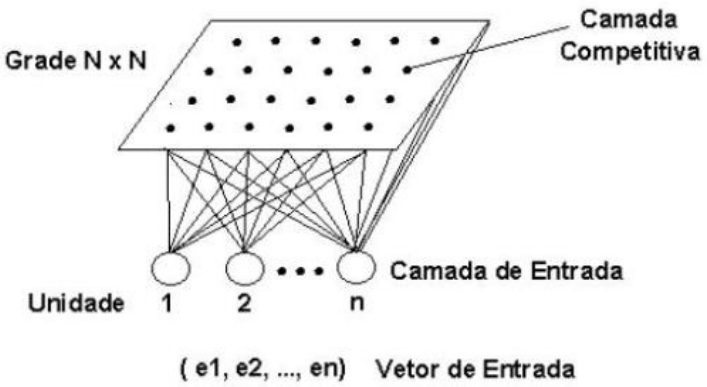

Figura 3.3 – Modelo de uma típica rede SOM

A rede SOM utiliza um algoritmo de aprendizado não supervisionado, ou seja, estão disponíveis para a rede apenas os padrões de entrada, dessa forma, não há uma saída desejada. Durante o processo de aprendizado os padrões são apresentados continuamente à rede, e consequentemente, ela deve se auto-organizar em relação às particularidades existentes entre os elementos do conjunto

total de amostras, identificando subconjuntos (*clusters*) que contenham similaridades, ou seja, padrões de entrada são organizados arbitrariamente em categorias (SILVA et al., 2010; BRAGA et al., 2007; AZEVEDO et al., 2000).

Os pesos sinápticos são ajustados de modo competitivo, em que os neurônios da camada de saída competem entre si para que apenas um seja ativado (o que gerar maior valor de saída) em determinado instante. Essa competição é chamada de *winner-takes-all*, o vencedor leva tudo (BRAGA et al., 2007). Para isso, são utilizadas conexões laterais inibitórias entre os neurônios de saída, pois caso o neurônio não responda a um padrão de entrada em particular, então não ocorrerá aprendizado nele especificamente, já se vencer a competição então cada nó de entrada deste neurônio libera certa proporção de seu peso sináptico e este peso será então distribuído uniformemente entre os neurônios de entrada ativos (HAYKIN, 2008). A unidade de saída com maior ativação inicial terá maior chance de disputa em relação às outras unidades, que perderão o poder de inibição ao longo do tempo. A unidade mais forte fica cada vez mais forte, e seu efeito inibidor sobre as outras unidades de saída torna-se dominante. Com o tempo todas as outras unidades de saída ficarão completamente inativas, exceto a vencedora (BRAGA et al., 2007).

De acordo com Braga et al. (2007) o treinamento busca agrupar os neurônios em classes, dessa forma, a rede descobre quantos grupos ela deve identificar e suas posições relativas no mapa. É afetado basicamente pelas seguintes variáveis: taxa de aprendizado, taxa de redução da vizinhança e pelo formato da região de vizinhança.

O treinamento da rede SOM ocorre em duas fases: convergência e ordenação. É durante a primeira fase do processo adaptativo que ocorre a organização topológica dos vetores de pesos, os quais são inicialmente orientados de forma aleatória. Este processo pode durar em torno de 1.000 ciclos ou iterações, além de provocar a diminuição da taxa de aprendizagem (inicialmente está próxima de 1, e é gradualmente reduzida até um valor próximo a 0,1). A mudança também ocorre com a função de vizinhança, que inicialmente inclui quase todos os neurônios da grade concentrados no neurônio vencedor, então diminui lentamente com o tempo, chegando ao valor de um par de neurônios vizinhos em torno do vencedor ou ao próprio neurônio vencedor (BRAGA et al., 2007; HAYKIN, 2008).

A segunda fase faz um ajuste mais fino do mapa, aprimorando o agrupamento realizado anteriormente. A etapa de convergência requer muito mais iterações,

devendo ser no mínimo 500 vezes o número de neurônios da grade. É utilizada uma taxa de aprendizado baixa, da ordem de 0,01, não permitindo que esta diminua a zero. O raio de vizinhança deve conter apenas os vizinhos mais próximos de um neurônio vencedor, que pode eventualmente se reduzir a um ou zero neurônios vizinhos (HAYKIN, 2008; BRAGA et al., 2007).

Haykin (2008) define o algoritmo da rede SOM em três passos básicos após a inicialização: amostragem, casamento por similaridade e atualização. Esses três passos são repetidos até a formação do mapa de características estar completo. O algoritmo é resumido da seguinte maneira:

a) Inicialização: atribuição de valores aleatórios aos vetores de pesos iniciais, os quais compreendem as conexões entre os neurônios da camada de entrada e saída.
b) Amostragem: é retirada uma amostra x, de dimensão m, do vetor de entrada representando o padrão de ativação que é aplicado à grade.
c) Casamento por similaridade: visa encontrar o neurônio vencedor, ou seja, aquele que possui o padrão mais próximo ou semelhante ao apresentado. Este processo é baseado na minimização da distância euclidiana entre os vetores x e w_j. O neurônio $i(x)$, que melhor casa com o vetor de entrada x, pode ser determinado aplicando a condição presente na equação 3.3, que resume a essência do processo competitivo entre os neurônios.

$$i(x) = \arg\min_j \left\| x(n) - w_j \right\| \qquad 3.3$$

d) Atualização: apenas os pesos das conexões entre os neurônios de entrada e a região composta pelo neurônio vencedor (sua vizinhança) serão atualizados a cada iteração. Desta forma, dado o vetor de peso sináptico $w_j(n)$ do neurônio j no tempo n, a atualização do vetor de peso é definida por $w_j = (n+1)$ na iteração $n+1$, conforme a equação 3.4.

$$w_j(n+1) = w_j(n) + \eta(n) h_{j,i(x)}(n)(x(n) - w_j(n)) \qquad 3.4$$

O termo $h_{j,i(x)}(n)$ corresponde à seleção da função de vizinhança. Já o parâmetro $\eta(n)$ representa a taxa de aprendizagem, cujo valor deve ser

alterado, ou seja, decresce gradualmente com o aumento das interações n, até que sejam completados todos os ciclos (τ_2) assim como apresentado na equação 3.5.

$$\eta(n) = \eta_0 \exp\left(-\frac{n}{\tau_2}\right) \qquad 3.5$$

e) Continuação: retorna ao passo (b) até que não sejam observadas mudanças significativas no mapa.

3.3 Descritores de Características

Características podem ser utilizadas como uma representação concisa de uma imagem (YAP et al., 2009). O formato de um determinado objeto pode ser considerado o atributo de maior relevância em características primitivas, pois tumores com bordas irregulares têm alta probabilidade de serem malignos e aqueles que mostram bordas regulares geralmente são benignos (SILVA, 2007).

A representação morfológica do objeto pode ser dada por diversas características:

1 – **Perímetro:** número de *pixels* presentes no contorno do objeto (ZHANG e Lu, 2004);

2 – **Área:** número total de *pixels* presentes no objeto (ZHANG e LU, 2004);

3 – **Fator Forma:** a forma do objeto, definida conforme equação (3.6):

$$FatorForma = \frac{4\pi \cdot Area}{Perimetro^2} \qquad 3.6$$

4 – **Razão de Área:** medida de porcentagem de tumor fora do comprimento radial normalizado. É obtida por meio da seguinte formulação (CHIANG et al., 2001; ALVARENGA et al., 2005):

$$RA = \frac{1}{DavgN}\sum_{i=1}^{N}(d(i) - Davg) \qquad d(i) - Davg = 0 \quad \forall d(i) \leq Davg \qquad 3.7$$

Em que, $Davg$ corresponde à média do comprimento radial normalizado, dado por:

$$Davg = \frac{1}{N}\sum_{i=1}^{N} d(i) \qquad 3.8$$

Já $d(i)$ representa a distância entre o centroide do tumor e o *pixel* de borda. Isso é determinado em toda a fronteira do objeto delimitado por meio da seguinte equação:

$$d(i) = \frac{\sqrt{(x(i)-X_0)^2 + (y(i)-Y_0)^2}}{\max(d(i))} \qquad i = 1,2,...,N \qquad 3.9$$

Em que, (X_0, Y_0) e $(x(i), y(i))$ são as coordenadas do centroide e *pixels* de borda, respectivamente.

5 – **Solidez:** representa a razão entre a área e a área convexa da lesão (YAP et al., 2009).

$$Solidez = \frac{Area}{AreaConvexa} \qquad 3.10$$

Além dessas medidas de formato mencionadas, muitas outras podem ser utilizadas em esquemas CAD para a obtenção de informações a respeito da região de interesse. Essas medidas, quando combinadas, representam bem as classes em que se dividem os achados suspeitos que serão posteriormente analisados.

3.4 Classificação

“Na área médica o reconhecimento de padrões é utilizado para caracterização de tumores, quantificação de deformidades de estruturas anatômicas, visualização de contornos e análises morfométricas, para auxílio ao diagnóstico” (PATROCINIO, 2004).

Para a execução da diferenciação entre lesões benignas e malignas, foi utilizada a rede *Perceptron* de Múltiplas Camadas (*Multilayer Perceptron* – MLP), a qual vem sendo aplicada com sucesso na resolução de problemas difíceis, devido a sua capacidade em tratar dados linearmente separáveis (HAYKIN, 2008).

A topologia da rede MLP consiste de unidades sensoriais que compõem a camada de entrada, uma ou mais camadas ocultas (camadas intermediárias), e uma camada de saída. A Figura 3.4 apresenta um grafo contendo a estrutura da rede MLP de duas camadas intermediárias, bem como o fluxo de informações, que tem início na camada de entrada, percorre as camadas intermediárias, sendo então finalizado na camada de saída (SILVA et al., 2010).

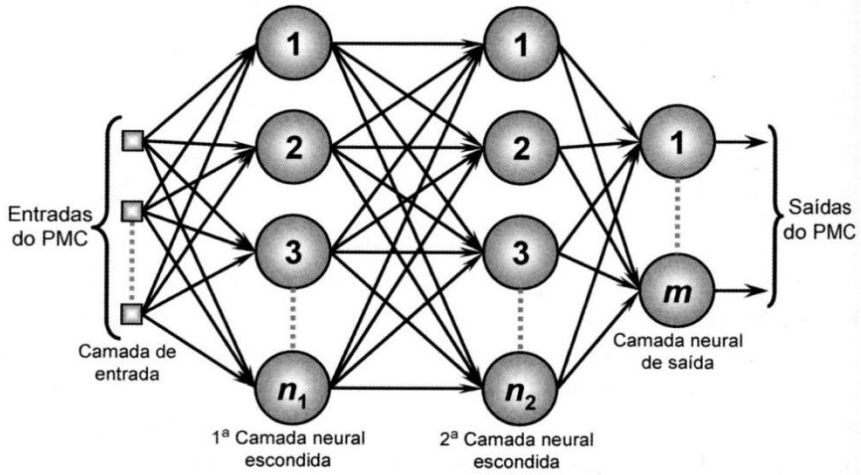

Figura 3.4 – Ilustração de rede *Perceptron* multicamadas
(Fonte: SILVA et al., p. 92, 2010)

A aprendizagem da rede MLP ocorre por meio de um processo supervisionado, que consiste em se ter disponíveis as respectivas saídas desejadas, ou seja, cada amostra de treinamento é composta pelos sinais de entrada e suas correspondentes saídas (SILVA et al., 2010; AZEVEDO et al., 2000). Dessa forma, os pesos sinápticos e limiares passam a ser continuamente ajustados mediante a aplicação de ações comparativas executadas pelo próprio algoritmo de aprendizagem, que supervisionam a defasagem entre as respostas produzidas pela rede em relação às desejadas, sendo essa diferença usada no procedimento de ajuste. A rede será considerada treinada quando tal defasagem estiver dentro dos valores aceitáveis, levando-se em consideração os propósitos de generalização de soluções (SILVA et al., 2010).

3.4.1 Treinamento

O algoritmo de treinamento de redes MLP mais comum é o de retropropagação do erro (*error backpropagation*), é comumente realizado mediante a aplicação sucessiva de duas fases, sendo elas *forward* e *backward*.

Na fase *forward*, os padrões a serem treinados são aplicados aos neurônios da camada de entrada e seu efeito se propaga através da rede, camada por camada, até produzir um conjunto de saídas como resposta real da rede. Durante a propagação, os pesos sinápticos são todos fixos (HAYKIN, 2008; BRAGA et al., 2007; SILVA et al., 2010). Já na fase *backward*, os pesos sinápticos são todos ajustados de acordo com uma regra de correção do erro, em que é calculado o desvio entre as respostas produzidas pelos neurônios de saída da rede em relação aos respectivos valores desejados. Esse valor é retropropagado contra as conexões sinápticas, promovendo o ajuste dos pesos e permitindo que a resposta real se aproxime da desejada (HAYKIN, 2008; BRAGA et al., 2007; SILVA et al., 2010).

Concluído o processo de treinamento, é verificada quantas épocas foram necessárias. Para tanto, a MLP será considerada totalmente treinada (ajustada) quando o erro quadrático médio entre duas épocas sucessivas for inferior à precisão requerida ao problema a ser mapeado (SILVA et al., 2010). A variável *época* pode também ser utilizada como critério de parada para a MLP em situações em que a precisão especificada para o problema se torna inalcançável, bastando definir sua quantidade máxima (SILVA et al., 2010; HAYKIN, 2008).

Há dois métodos utilizados pela MLP para avaliar a generalização de um modelo a partir de um conjunto de dados, sendo eles: *cross-validation* e *leave-one-out*. O *cross-validation* (ou validação cruzada) ocorre quando há um grande conjunto de amostras selecionadas para o treinamento neural; ocorre por meio do particionamento aleatório desse conjunto em dois grupos: treinamento – cerca de 70 a 90% da quantidade de itens, e validação – de 10 a 30% dos itens. Já o *leave-one-out* é empregado para conjuntos com pouca variedade de amostras; o seu conjunto de validação nunca se repete e é composto pelo único elemento que ficou de fora do treinamento (HAYKIN, 2008).

A partir da generalização do classificador, a rede MLP pode ser utilizada para estimar as saídas do sistema que foi mapeado frente às novas amostras que serão apresentadas em suas entradas.

4 MATERIAIS E MÉTODOS

Este trabalho foi dividido em vários experimentos com o objetivo de promover uma maior investigação na diferenciação de nódulos benignos e malignos em imagens simuladas e clínicas de ultrassonografia da mama.

Esse processo pode ser alcançado por meio de, basicamente, três etapas. A primeira constitui-se no processamento digital da imagem, em que foram abordadas questões envolvendo tanto a melhoria na sua qualidade quanto a detecção do objeto de interesse. Já a segunda etapa diz respeito à extração de características que possam descrever o objeto, e seleção das mais significativas. Por fim, temos a classificação, em que as características escolhidas, na etapa anterior, servirão de entrada para a RNA, e esta irá fornecer a tendência da lesão selecionada ser benigna ou maligna.

4.1 Banco de Imagens

O banco de imagens que vem sendo utilizado neste trabalho consiste de 292 ultrassonografias clínicas da mama, adquiridas durante procedimentos de rotina para o diagnóstico da mama. Essas imagens foram fornecidas pelo Centro Integrado

de Diagnóstico por Imagem, na Irmandade Santa Casa da Misericórdia de São Carlos/SP, e pela Clínica Focus Diagnóstico de São Carlos/SP.

As ultrassonografias modo-B foram obtidas por intermédio de quatro equipamentos, sendo eles: aparelho Siemens G50, Medison, Toshiba e General Electric. Sua aquisição decorreu do uso de um transdutor de matriz linear com frequências de 7.5 MHz a 10 MHz. As imagens foram capturadas com 8 bits de resolução de contrate (256 níveis de cinza), armazenadas em formato TIFF. A quantidade de imagens adquiridas por cada equipamento está disposta na Tabela 4.1.

Tabela 4.1 – Total de imagens clínicas obtidas em cada equipamento

	Aparelhos				**Total**
	GE	**Toshiba**	**Medison**	**Siemens**	
Quantidade de Imagens	111	48	50	83	292

Com base nos exames fornecidos, foram determinadas as imagens que possuíam alguma lesão, considerando tanto as benignas quanto as malignas. Os exames com ausência de quaisquer tipos de achados, que pudessem levar a investigação, foram descartados.

Outro fator que levou a desconsiderar alguns exames foi a presença de marcações, realizadas pelo radiologista antes do salvamento das imagens, pois, ao estar muito próximas ou transpassando a lesão, prejudicariam a execução do processamento digital.

Essas marcações são necessárias para a determinação de algumas medidas, tais como diâmetro anti-radial (largura), diâmetro radial (altura) e distância entre a lesão e o mamilo. A Figura 4.1 expõe um exemplo dessa situação.

Figura 4.1 – Imagem clínica de ultrassonografia da mama com as marcações do radiologista

Quando a imagem é submetida ao sistema desenvolvido, cabe ao especialista realizar o recorte da ROI, como exibido na Figura 4.2 (a). Determinada a região que contém a lesão, o sistema deve promover a detecção da mesma, representada pela Figura 4.2 (b).

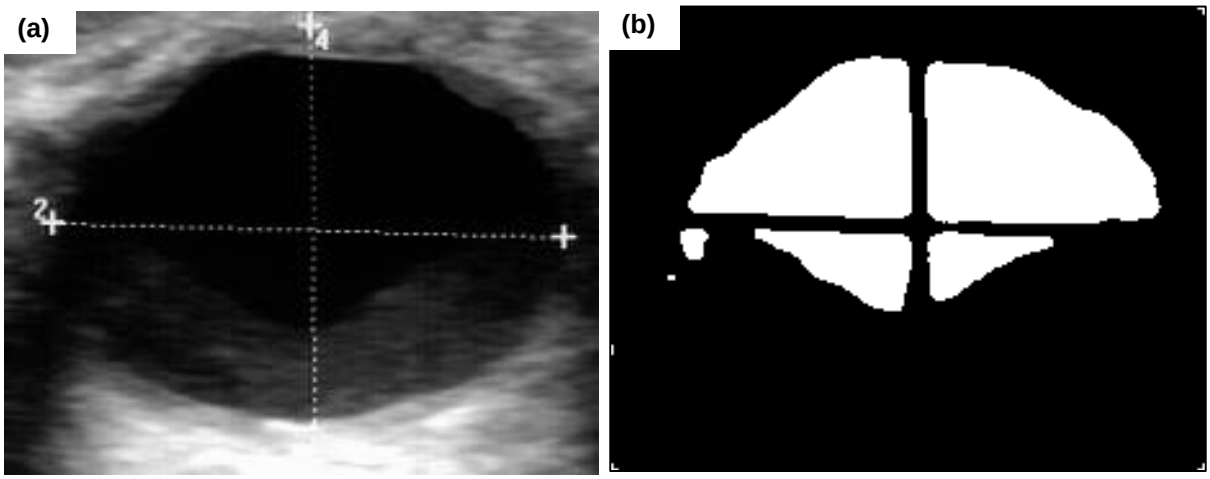

Figura 4.2 – (a) Recorte da ROI; (b) resultado da detecção

Podemos notar a interferência que a marcação exerce na determinação do achado suspeito, em que a linha de medida ocasiona a divisão do objeto de interesse, dando a entender que a imagem contém mais de uma estrutura. Isto se deve à separação da lesão, fazendo com que a linha se torne uma fronteira, refletindo diretamente sobre a segmentação.

Como esse fenômeno influencia negativamente na detecção, optou-se pela remoção das imagens que apresentassem essas características.

Diante das circunstâncias mencionadas, dos 292 exames adquiridos, apenas 126 puderam ser levados em consideração. A nova distribuição entre a quantidade de ultrassonografias por equipamento é exibida na Tabela 4.2.

Tabela 4.2 – Total de imagens clínicas com achado suspeito

	Aparelhos				**Total**
	GE	**Toshiba**	**Medison**	**Siemens**	
Quantidade de Imagens	54	21	18	33	126

Outro aspecto que pôde ser notado está relacionado à diferença que cada tipo de equipamento exerce na qualidade da imagem, como é representado pela Figura 4.3. Os aparelhos da (a) General Electric e (b) Medison oferecem representações mais suavizadas quando comparadas com as da (c) Siemens e (d) Toshiba, cujas características dos objetos tendem a ser mais ruidosas e com padrão mais granuloso.

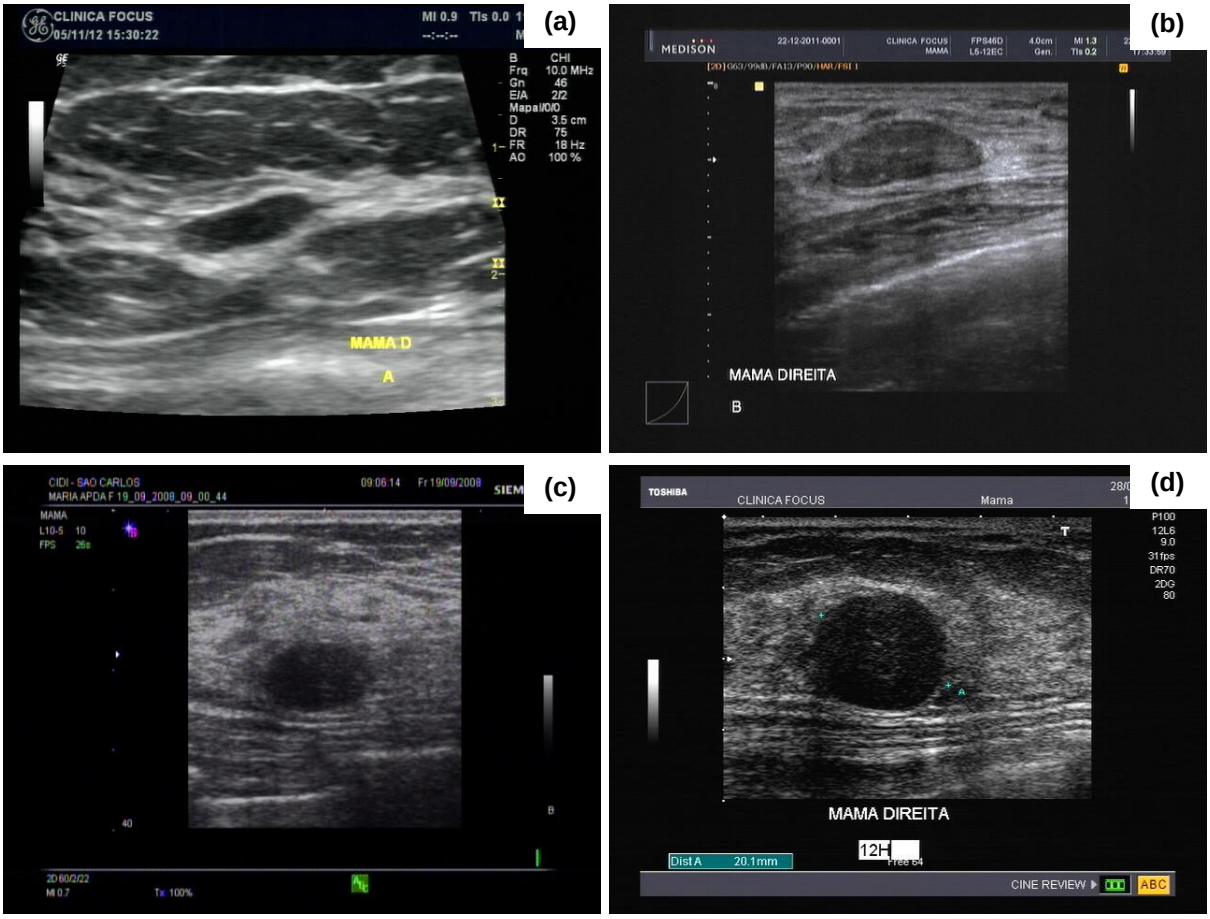

Figura 4.3 – Imagens clínicas de ultrassonografia da mama adquiridas pelos equipamentos: (a) General Electric, (b) Medison, (c) Siemens G50, (d) Toshiba

Além das imagens clínicas, também são aplicados testes em imagens simuladas (de *phantoms*) para a validação dos métodos empregados. As características de obtenção e confecção desses *phantoms* são descritas a seguir.

4.1.1 Phantoms

Phantoms ultrassônicos são simuladores de tecidos biológicos que mimetizam suas características, bem como possibilitam o estudo da interação do mesmo com o US, além de auxiliar no treinamento de biópsias, treinamento de profissionais e na calibração de equipamentos. A construção desses *phantoms* deve ser baseada nas propriedades do material mimetizante, apresentando parâmetros acústicos médios dos tecidos biológicos, como por exemplo, velocidade de propagação da onda no meio, coeficiente de atenuação e impedância acústica (CARVALHO, 2009).

O Grupo de Inovação em Instrumentação Médica e Ultrassom (GIIMUS), do Depto. de Física da FFCLRP/USP, adquiriu o simulador ATS Laboratories, modelo BB-1 – *Breast Biopsy Phantom*[2], cuja representação é fornecida pela Figura 4.4.

Vieira (2005) apresentou as bases físicas para a confecção de um *phantom*, o qual é constituído por gelatina à base de hidrocarbonetos saturados com adição de microestruturas espalhadoras (pó de vidro) à substância basal – 4% de concentração. Foram também acrescentadas inclusões para representar diferentes ecogenicidades e atenuações, visando simular os tipos mais comuns de lesões encontradas na mama. A ecogenicidade foi controlada mudando a concentração de partículas espalhadoras (quanto maior a concentração, maior a ecogenicidade). Já a atenuação foi controlada adicionando cera de carnaúba. Cistos fluidos foram preparados com mel de abelha. As lesões foram tingidas com alanina para facilitar a sua identificação durante a biópsia. A Figura 4.5 ilustra os *phantoms* confeccionados por Vieira (2005), bem como o aperfeiçoamento no desenvolvimento de novos.

Figura 4.4 – *Phantoms* comerciais adquiridos pelo GIIMUS

[2] Maiores informações disponíveis em: <http://atslaboratories-phantoms.com/images/TrainingPhantoms.pdf>

Figura 4.5 – *Phantoms* desenvolvidos pelo GIIMUS

Os *phantoms* foram expostos a feixes de US, e coletadas 144 imagens no laboratório do GIIMUS em Ribeirão Preto/SP. A Figura 4.6 ilustra algumas imagens contendo inclusões obtidas com os *phantoms* exibidos nas Figura 4.5 e Figura 4.4.

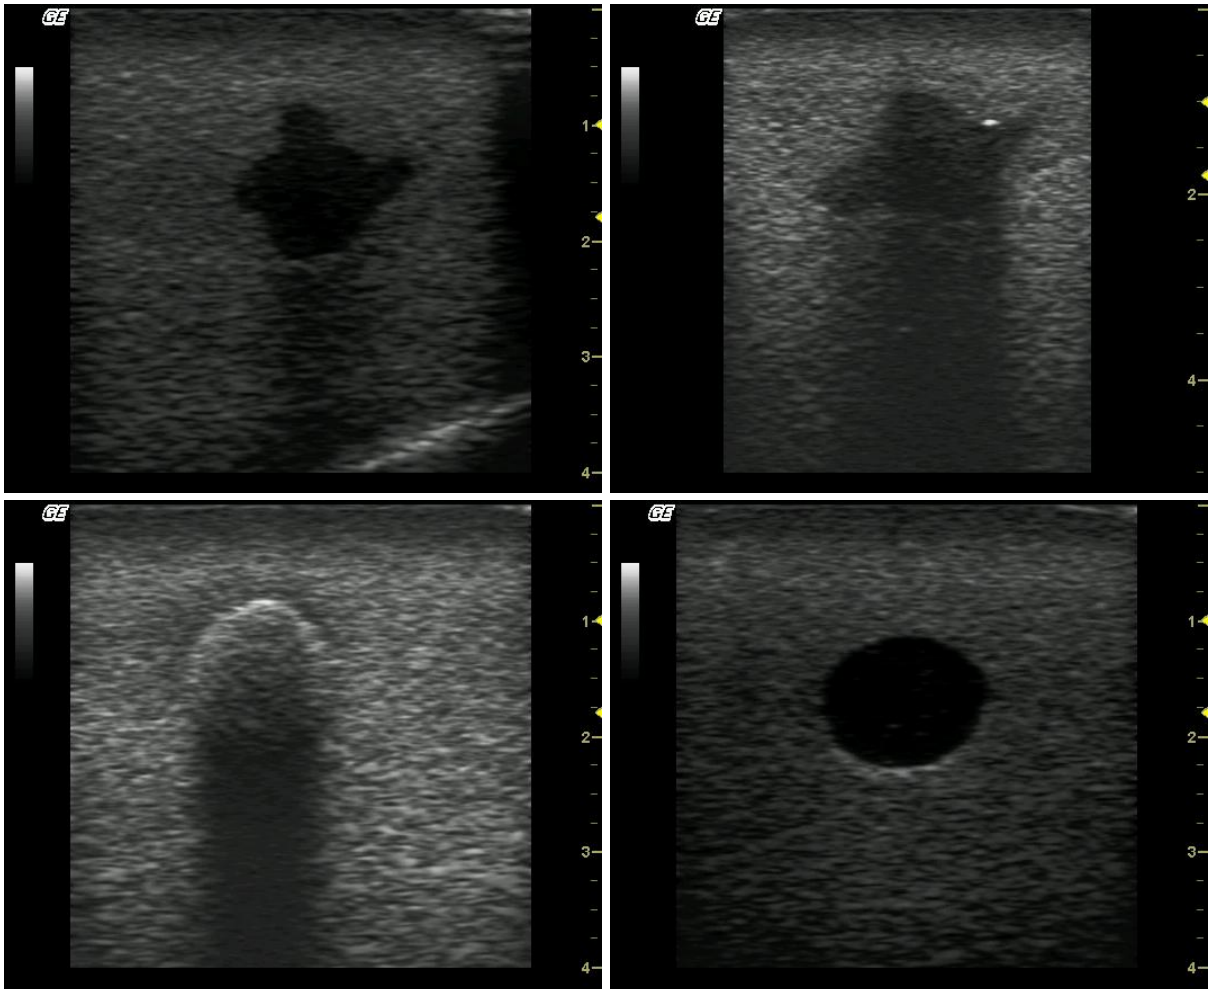

Figura 4.6 – Imagens da ultrassonografia obtida por meio dos *phantoms*

4.2 Processamento Digital

Para cada imagem de ultrassom adquirida, uma radiologista experiente determinou a localização de uma ou mais massas suspeitas e, em seguida, realizou os recortes que julgou necessário. Esses recortes são denominados de regiões de interesse (ROIs – *Regions of Interest*), possuem formato retangular e incluem a lesão e tecidos adjacentes, sendo obtidas por meio do *software ImageJ* versão 1.45. Na Figura 4.7 temos o exemplo de uma imagem clínica adquirida por um aparelho de ultrassom, com o respectivo recorte efetuado pelo radiologista.

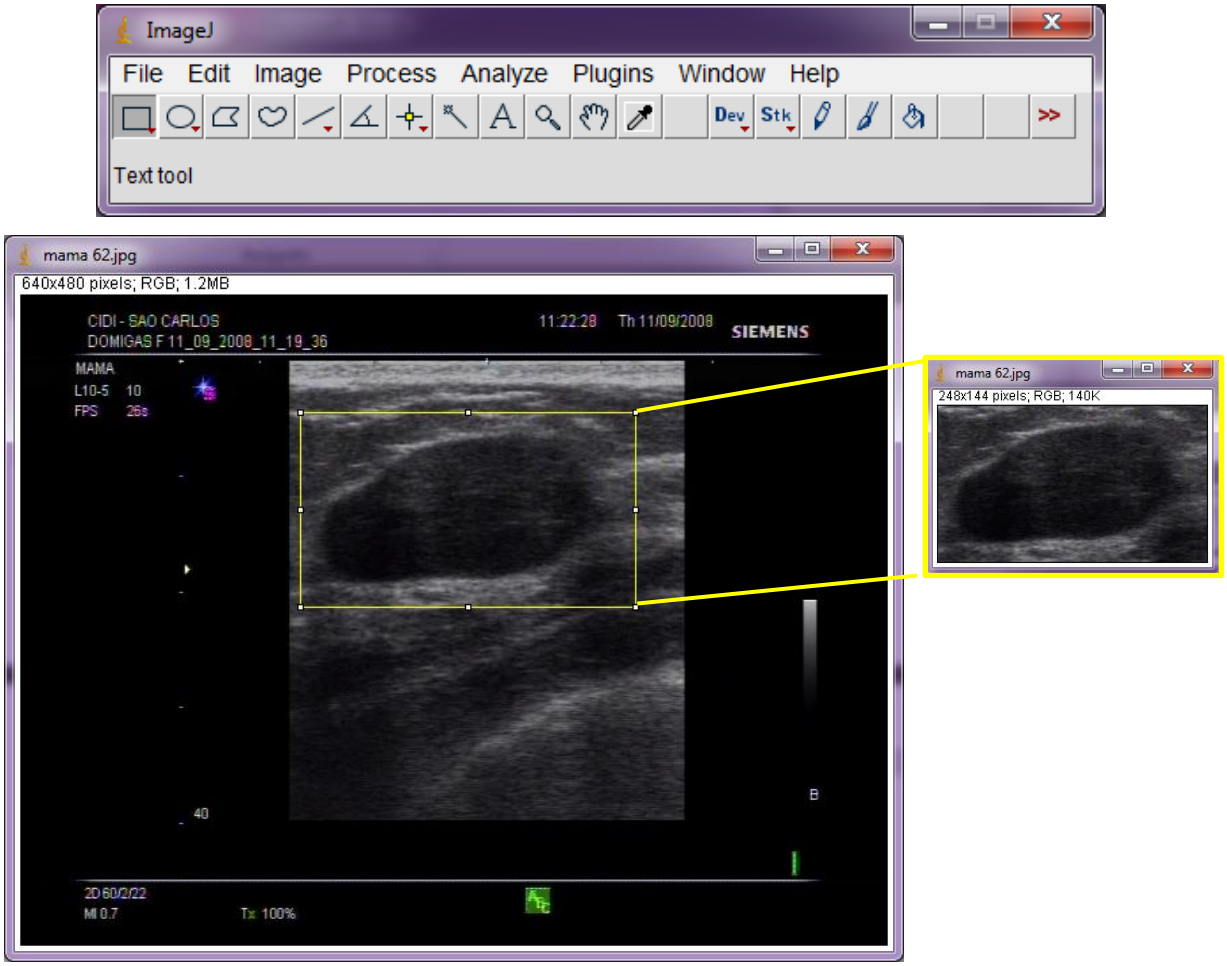

Figura 4.7 – Imagem clínica de uma ultrassonografia da mama e o respectivo recorte da ROI

A partir dos 126 exames de ultrassonografia clínica da mama que apontavam algum achado suspeito, foram determinadas e recortadas, por uma radiologista, as regiões contendo a lesão. Isso proporcionou um total de 173 ROIs, pois alguns exames compreendiam mais que uma lesão. A Tabela 4.3 assinala a quantidade de ROIs obtidas de cada equipamento.

Tabela 4.3 – Total de ROIs de ultrassonografias clínicas com achados suspeitos

	Aparelhos				Total
	GE	Toshiba	Medison	Siemens	
Quantidade de Imagens	71	25	27	50	173

Já nas imagens adquiridas por simuladores, as inclusões estavam em localizações equidistantes umas das outras. Assim, não era possível o aparecimento

de mais de um objeto na mesma imagem. Portanto, das 144 imagens simuladas, a mesma quantia de ROIs foi extraída.

A partir dessas ROIs, foram testados diversos algoritmos, tanto de suavização do ruído quanto de segmentação, procurando encontrar o que fornecesse o delineamento mais adequado da lesão.

4.2.1 Pré-Processamento

O pré-processamento da imagem é realizado para remover a redundância ou o ruído indesejado nas imagens e melhorar os dados constituintes, bem como, informações importantes para o posterior processamento (CHANG, 2005).

De acordo com Michailovich e Tannenbaum (2007) o desempenho de algoritmos de segmentação pode ser melhorado substancialmente pela aplicação do pré-processamento ao invés de processar diretamente as imagens originais. A ideia geral é reduzir o ruído *speckle*, presente em imagens de ultrassom, antes da segmentação, como uma etapa de pré-processamento (XU, 2009).

Desta maneira, as ROIs foram, inicialmente, submetidas à filtragem de W*iener*, com janela de vizinhança 5x5, para a minimização do ruído aditivo. Em seguida, o contraste foi aumentado através da equalização da imagem. E por fim, realizou-se a filtragem pela mediana, com janela de vizinhança 7x7, permitindo a suavização de ruídos (remoção de possíveis “pontos brilhantes” que aparecem na imagem devido ao alargamento de contraste) (MARCOMINI e SCHIABEL, 2012a).

4.2.2 Segmentação

Segundo Pratt (2007), para se alcançar uma boa segmentação, as regiões devem ser uniformes e homogêneas em relação a alguma característica, tais como tons de cinza ou textura. O interior da região deve ser simples e sem muitos buracos pequenos. As regiões adjacentes precisam ter valores significativamente distintos em relação às características nas quais elas são uniformes. Por fim, as bordas precisam ser simples, ou seja, únicas e contínuas.

Teng e Chang (2011) propõem a aplicação de diversas técnicas de segmentação a fim de desenvolver uma abordagem geral de processamento em imagens médicas. Em seu trabalho, destacam a utilização das técnicas de crescimento de região, contorno ativo e métodos de agrupamento. Nesse intuito, propomos cinco diferentes técnicas automáticas de detecção, sendo elas: contorno ativo, crescimento de região, *k*-means, fuzzy c-means e a rede neural SOM para verificar também o efeito de técnicas de inteligência artificial na segmentação dessas estruturas.

A técnica de contorno ativo, também chamada de *snakes*, consiste em minimizar a energia através da deformação de um contorno inicial em conjunto de forças internas e externas (ALÉMAN-FLORES et al., 2005; CVANCAROVA et al., 2005).

O desenvolvimento do contorno ativo nesse trabalho teve por base o algoritmo apresentado por Sandhu et al. (2008). Porém, o contorno inicial é proporcionado de forma diferenciada, que neste caso, dá-se pela inserção de um retângulo localizado no centro da imagem, cujo tamanho varia de acordo com a dimensão da ROI, pois foi levado em consideração que quanto maior ela se apresentar, maior deverá ser o tamanho do nódulo presente. A proporção utilizada foi de 60% da quantidade de *pixels* constituintes em sua altura e largura, ou seja, para uma ROI com tamanho de 120x200 *pixels*, por exemplo, o retângulo, disposto no centro da imagem, terá a dimensão de 96x120 *pixels* (MARCOMINI et al., 2012; MARCOMINI et al., 2013). Na Figura 4.8 é demonstrada a disposição do contorno inicial.

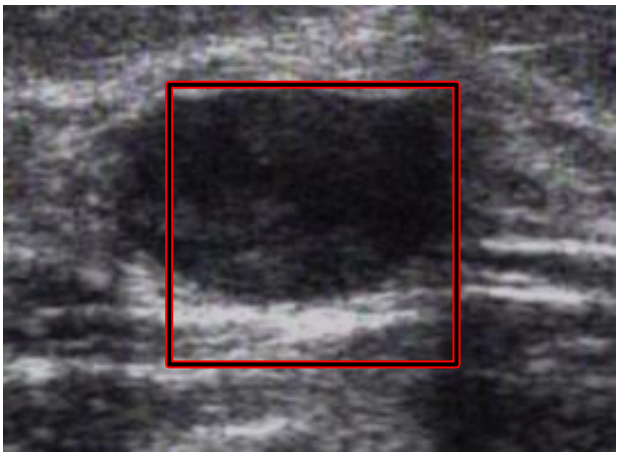

Figura 4.8 – Disposição inicial do contorno ativo

Definido o tamanho do contorno inicial, o mesmo tende a ser alongado ou flexionado, de acordo com a similaridade encontrada na região em que está presente. Para que fosse possível maior adequação do contorno ao objeto, o processo constituiu de 1.000 interações, com energia de curvatura equivalente a 0,005 (MARCOMINI et al., 2012; MARCOMINI et al., 2013).

Já o principal algoritmo de segmentação baseado em região, por definição de um limiar, inclui a técnica de crescimento de região. O limiar é utilizado para distinguir a diferença entre os níveis de cinza do objeto de interesse e o fundo (ZHU et al., 2009b). É um procedimento que tem por objetivo agrupar os *pixels* vizinhos conexos ou sub-regiões em regiões maiores, com base no critério de similaridade, formando a região segmentada (GONZALEZ e WOODS, 2010; PRATT 2007; SILVA, 2003; SANTOS, 2002).

O processo inicia com a escolha de ao menos um ponto inicial (semente) por região. Incialmente cada *pixel* é rotulado como uma região distinta. A escolha desses pontos pode ser manual (fornecida pelo operador) ou automática (o processo a encontra) (GONZALEZ e WOODS, 2010; PRATT, 2007; SILVA, 2003). No presente caso, foi realizado de maneira automática, cujo valor utilizado representa a maior intensidade de cinza na imagem, ou seja, ao valor 255 (imagens com 8 *bits* de resolução de contraste) (MARCOMINI e SCHIABEL, 2012b; MARCOMINI et al., 2013).

Na próxima etapa, os *pixels* vizinhos são examinados; caso satisfaçam o critério de similaridade, são adicionados à região. O critério de similaridade baseia-se em um teste de hipótese estatístico que testa a média entre as regiões. A seguir, divide-se a imagem em um conjunto de sub-imagens e então é feita a união entre elas, segundo um limiar de agregação definido (SANTOS, 2002; PRATT, 2007). Esse limiar corresponde ao cálculo dado pelo valor médio da intensidade de níveis de cinza pertencentes à ROI (MARCOMINI e SCHIABEL, 2012b). O processo continua até que nenhum *pixel* seja adicionado, reunindo, portanto, as regiões adjacentes à semente em uma fronteira comum. O objeto é então representado por todos os pixels aceitos durante o crescimento (BANKMAN, 2009; SILVA, 2003; PRATT, 2007; GONZALEZ e WOODS, 2010).

Há ainda os métodos de agrupamento, que não necessitam de amostras de treinamento, tornando-se um agrupamento estatístico não supervisionado. Ocorre um tipo de auto-treinamento, cuja classificação tem por base a imagem original. É

um processo sensível ao ruído, pois não leva em consideração a formação espacial dos níveis de cinza (não avalia a vizinhança), o que pode proporcionar o agrupamento de *pixels* isolados e, ao determinar o objeto de interesse, tende a formar regiões com pequenos pontos separados espacialmente (ZHU et al., 2009b). Neste quadro temos os algoritmos *k*-means e fuzzy c-means.

O algoritmo *k*-means busca diminuir a quantidade de níveis de cinza da imagem original, a partir da escolha do número de grupos ou *clusters*. A função de minimização pode ser obtida assumindo que a quantidade de *clusters* é conhecida, permanecendo na imagem apenas a quantia de intensidades determinadas (TAKAHASHI et al., 2005; FORSYTH e PONCE, 2003). Adotou-se aqui a quantidade de 2 *clusters*, admitindo uma imagem binária (MARCOMINI et al., 2013).

O processo se inicia com a apresentação da imagem, a quantidade de grupos e a posição de cada centroide (escolhida aleatoriamente) – suas posições iniciais são de muita influência no resultado. Em seguida, é verificada a similaridade entre os *pixels* com cada centroide. Após a verificação, o *pixel* é alocado com o grupo do centroide similar mais próximo. Logo, o centroide é substituído pelo valor médio dos elementos contidos em seus *clusters*. A atualização só é concluída quando não houver mais variação dos *pixels* entre os grupos, ou seja, se o centroide não alterar em relação ao anterior significa que houve a convergência do resultado (MARCOMINI e SCHIABEL, 2012b).

O fuzzy c-means (FCM) é um algoritmo interativo de agrupamento generalizado do *k*-means. O seu diferencial está no cálculo do centroide do *cluster* e a regra de atualização de seus membros; além disso, permite que determinados padrões estejam associados a mais de um grupo (SONKA e FITZPATRICK, 2000; XU, 2009).

Como no *k*-means, são apresentados o número de *clusters* (apenas 2 grupos), e logo em seguida, é inicializado o centroide para cada *cluster* (sua posição inicial é dada pelas intensidades máxima e mínima dos níveis de cinza, ou seja, 255 e zero, respectivamente). Então, o centroide é encontrado pela função de minimização, e verificada sua pertinência. A partir daí, é criado um mapa contendo a posição dos *pixels* alocados no *cluster*. Adicionando o *pixel* ao *cluster*, o valor do centroide é atualizado, e esse processo se repete até que não haja mudança no resultado final (MARCOMINI e SCHIABEL, 2012b; MARCOMINI, et al., 2013).

Por fim, outra técnica que vem sendo amplamente utilizada para a resolução dos problemas de segmentação de imagens médicas é a de redes neurais (ZHU et al., 2009b). Para isso, a rede SOM foi montada com estrutura topológica quadrática de 10 unidades sensoriais na camada de entrada, totalmente conectados à grade de 10x10 neurônios. Os pesos iniciais são obtidos de maneira aleatória (MARCOMINI e SCHIABEL, 2012a; MARCOMINI et al., 2013).

Durante a fase de amostragem, dois padrões de entrada são coletados (compreendem os valores correspondentes às cores branca – equivalendo a 255, e preta – a zero), para os quais os dados de saída devem convergir durante a etapa de treinamento. Na sequência, o neurônio vencedor é encontrado (o mais similar entre os padrões apresentados), bem como sua área de influência – raio para o qual ocorre a atualização, em que os pesos dos neurônios envolvidos são atualizados. O processo de convergência deve ser realizado em no máximo 1000 ciclos (MARCOMINI e SCHIABEL, 2012a).

Finalmente, a rede recebe a imagem de entrada e a classifica de acordo com os valores obtidos na etapa anterior, convergindo o mapa de borda em apenas duas classes. Esse processo retorna a fase de amostragem e continua o treinamento até que não sejam observadas mudanças significativas no mapa (MARCOMINI e SCHIABEL, 2012a).

4.2.3 Pós-Processamento

Após a binarização da imagem, é necessária a remoção de alguns artefatos que são prejudiciais à fase de classificação (SHAN et al., 2008). Para isso, foi desenvolvido um algoritmo que visa à remoção dos ruídos remanescentes da segmentação. Assim, foi considerado que cada ROI possui apenas uma lesão, e consequentemente é representada pela região com maior área. O processo se inicia pela análise de *pixels*: caso o *pixel* vizinho ao considerado possua conectividade (8-conectado) com a região de maior área, ele é mantido na imagem resultante, caso contrário, é considerado como ruído e removido. Por fim, é verificada a presença de vales internos; se existirem, os *pixels* são adicionados à área segmentada, permanecendo apenas um único objeto (MARCOMINI e SCHIABEL, 2012a; MARCOMINI et al., 2012).

4.3 Métodos de Avaliação

A precisão das técnicas de segmentação foi avaliada através de medidas quantitativas, derivadas da comparação de cada ROI segmentada com seu “padrão ouro” (*gold standard*) correspondente. O padrão ouro, comumente também é conhecido como “*ground truth*” (GT), foi gerado pela segmentação manual do contorno da lesão, em que uma radiologista, utilizando o *software ImageJ* 1.45, identificou e delimitou o contorno da área suspeita (WIRTH et al., 2005).

A Figura 4.9 demonstra um exemplo de como a radiologista demarcou o contorno manualmente. Isso ocorre por meio da (a) inserção de pontos sobre os limites da lesão, estes se interligam e representam a (b) forma do objeto. Esse é um processo que exige muito do especialista, pois requer alto grau de precisão e um tempo razoável. Caso os pontos se apresentem muito espaçados, o objeto perde um pouco a circularidade de sua forma.

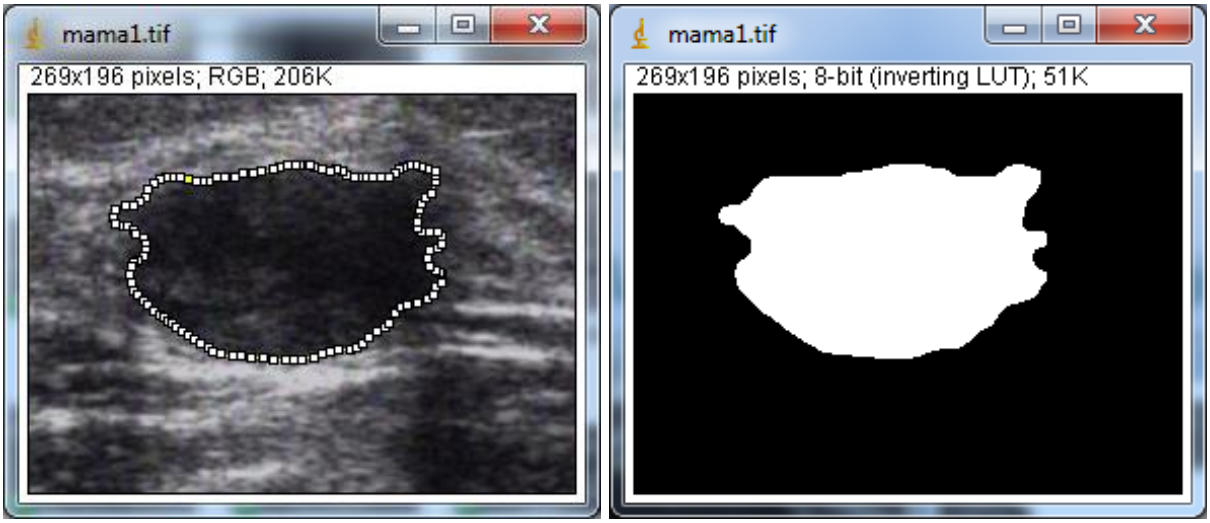

Figura 4.9 – Contorno delineado pelo radiologista

Ao aplicar um detector de região a um objeto, têm-se quatro situações distintas. Se a área correspondente ao GT (*pixels* considerados genuínos ou positivos) coincide com a região segmentada (positiva), tem-se um verdadeiro positivo (VP), ou seja, o algoritmo encontrou uma porção da massa realmente suspeita; no entanto, se o classificador considerou a região negativa, conta-se como falso negativo (FN), então considerados *pixels* desaparecidos. Por outro lado, se os *pixels* não pertencentes ao GT (impostores ou negativos) são classificados como tal,

conta-se como verdadeiro negativo (VN); porém, se estes pixels estiverem presentes na segmentação (positivos), serão definidos como falso positivo (FP) (WIRTH et al., 2005; FAWCETT, 2006). Nestes dois últimos casos aparecem *pixels* inexistentes.

A partir desses conceitos, é possível a elaboração de uma tabela de contingência ou também conhecida por matriz de confusão, relacionando os dados descritos acima, que se encontra exemplificada pela Tabela 4.4.

Tabela 4.4 – Matriz de confusão

Ground-Truth / Segmentada	Pixel Positivo	Pixel Negativo
Pixel Positivo	VP	FP
Pixel Negativo	FN	VN

Outra forma de compreender essas nomenclaturas dá-se por meio da representação fornecida pela Figura 4.10, em que são exibidas as duas regiões, manual e segmentada, sobrepostas.

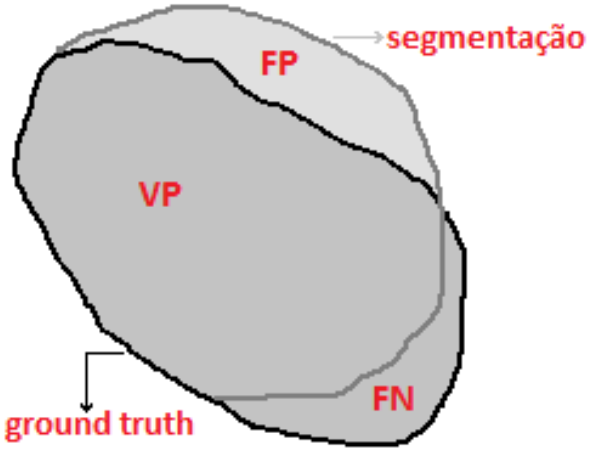

Figura 4.10 – Índice de desempenho: VP, FP, FN

Esses dados servem como base para muitas métricas, que podem ser aplicadas para analisar as características de um detector de bordas ou de região. Dentre as principais métricas que podem ser calculadas destacam-se: acurácia, taxa de erro, razão de verdadeiros positivos (RVP), valor preditivo positivo (VPP), *area overlap measure* (AOM) e medida de combinação (CM) (BOAVENTURA, 2010).

A acurácia (exatidão ou taxa de acerto) é a proporção de classificações corretas para o total de elementos classificados (genuínos e impostores) (Boaventura, 2010). A acurácia é calculada pela seguinte equação:

$$A = \frac{VP + VN}{VP + FN + FP + VN} \qquad 4.1$$

A taxa de erro é a proporção de classificações incorretas para o total de elementos (genuínos e impostores) (BOAVENTURA, 2010). Sua equação está apresentada abaixo:

$$Err = \frac{FP + FN}{VP + FN + FP + VN} \qquad 4.2$$

Razão de verdadeiros positivos, também chamada de sensibilidade, é a proporção do GT, ou seja, os genuínos que foram identificados corretamente na segmentação (VP). O valor obtido varia de 0 a 1, com 0 indicando que nenhuma das regiões encontra-se presente no GT, e 1 indicando que as regiões foram muito bem segmentadas. (WIRTH et al., 2005; BOAVENTURA, 2010). O cálculo é dado pela equação 4.3.

$$RVP = \frac{VP}{VP + FN} \qquad 4.3$$

Já a razão de falsos positivos (RFP) é o oposto da RVP, ou seja, mede a proporção de impostores classificados como genuínos. Seu equacionamento segue abaixo (FAWCETT, 2006).

$$RFP = \frac{FP}{VN + FP} \qquad 4.4$$

O VPP (verdadeiro preditivo positivo) representa a proporção de *pixels* da região segmentada (positivos) que foram classificados corretamente (VP). Assim

como a sensibilidade, o valor ideal para o VPP é 1. Quando a sensibilidade possui baixo valor, é um sinal de que houve excessiva segmentação (*over-segmentation*). Já a falta na segmentação (*under-segmentation*) é definida pelo baixo valor do VPP (WIRTH et al., 2005). Seu cálculo é dado através de:

$$VPP = \frac{VP}{VP + FP} \qquad 4.5$$

A medida *quality* (Q) foi utilizada por Wirth et al. (2005) para averiguar a taxa de acerto final da segmentação, considerando os valores correspondentes a falta e excesso na segmentação. O valor considerado ideal deve igualar-se a 1. Sua definição é dada por:

$$Q = \frac{VP}{FN + FP + VP} \qquad 4.6$$

A métrica *area overlap measure* (AOM) é outra maneira de quantificar a consistência da segmentação. Nada mais é do que a razão entre a união e a intersecção das duas áreas a serem comparadas, avaliando a quantidade de tecido em comum (PEI et al., 2010; GÓMEZ, et al., 2010). Sendo assim, temos:

$$AOM = \frac{A_{seg} \cap A_{gt}}{A_{seg} \cup A_{gt}} \qquad 4.7$$

em que A_{seg} indica a área segmentada automaticamente, e A_{gt} corresponde à área do GT.

Seu resultado abrange a faixa de 0 a 1, e quanto maior o valor, melhor é o resultado proporcionado pelo detector. No entanto, o AOM não fornece informações de falta ou excesso na segmentação. Para obter esse tipo de esclarecimento, foram calculadas as medidas de *area under-segmentation* (AUM) e *area over-segmentation* (AVM), cujos cálculos são apontados nas equações 4.8 e 4.9 (PEI et al., 2010).

$$AUM = \frac{(A_{gt} - A_{seg})}{A_{gt}} \qquad 4.8$$

$$AVM = \frac{(A_{seg} - A_{gt})}{A_{seg}} \qquad 4.9$$

A medida de combinação (CM – *Combination Measure*) fornece a precisão do segmentador com base na associação das métricas AOM, AUM e AVM (PEI et al., 2010), conforme a equação abaixo:

$$CM = \frac{(AOM) + (-AUM) + (-AVM)}{3} \qquad 4.10$$

4.4 Extração e Seleção de Características

A extração e seleção das características das imagens são passos críticos para a identificação de objetos (SILVA, 2007). Raramente se usa apenas uma medida de cada padrão para que o investigador decida a qual classe pertence o caso observado. O mesmo ocorre quando se procura classificar automaticamente estruturas detectadas em um exame digital de imagem médica. O mais comum é extrair várias medidas de cada padrão e representá-las através de um vetor, o qual servirá de entrada para um classificador automático (PATROCINIO, 2004).

De um modo geral, tumores benignos geralmente têm formas suaves; já tumores malignos tendem a apresentar bordas irregulares (CHANG et al., 2005). A partir dessa proposição, foram extraídas 25 características morfológicas de cada lesão, sendo elas: perímetro, distância de Hausdorff (fornece uma medida da distância entre duas curvas ou conjunto de pontos diferentes; quanto menor a distância, maior a semelhança entre as partes), área (ZHANG e LU, 2004), razão área perímetro, razão raio máximo e mínimo (YAP et al., 2009), convexidade, solidez, retangularidade (PEURA e IIVARINEN, 1997; MINGGIANG et al., 2008; CHANG et al., 2005; RUSS, 1995; YAP et al., 2009), desvio padrão, rugosidade, razão de área (ALVARENGA et al., 2005; CHIANG et al., 2001), variância circular,

variância elíptica, razão do eixo principal (PEURA e IIVARINEN, 1997; MINGGIANG et al., 2008), resíduo (ALVARENGA et al., 2005).

Algumas características foram encontradas na literatura com o mesmo nome, porém com formulações distintas. Dessa forma, foram consideradas como descritores diferenciados entre si. Assim, temos os descritores de compacidade e elongação propostos por Minggiang et al. (2008) e Yap et al. (2009). No cálculo da circularidade há as formulações propostas por Zhang e Lu (2004) e Yap et al. (2009). Já a excentricidade é dada por Zhang e Lu (2004) e a que se encontra presente no *Toolbox* de Imagens do MATLAB[3]. Por fim, Russ (1995) difere de Yap et al. (2009) quanto ao fator forma.

Mediante as múltiplas características apresentadas, um dos principais problemas é como encontrar um conjunto reduzido de características que descrevam a imagem com precisão suficiente para sua identificação. Deve-se ressaltar que a percepção humana é bastante subjetiva e, portanto, o uso de um único descritor para a representação não é, em geral, suficiente (SILVA, 2007).

Assim, os atributos extraídos das imagens são analisados estatisticamente para que sejam mantidos apenas aqueles que realmente descrevem padrões singulares de cada classe.

Um dos métodos de parametrização dos dados dá-se por meio da distribuição Gaussiana (PATROCINIO et al., 2010; PATROCINIO et al., 2002), com implementação no *software MATLAB* versão 7.7.0 (R2008b). Cada descritor é normalizado e, em seguida, é gerada a curva Gaussiana referente à distribuição dos valores para cada classe (nesse caso, apenas 2 classes).

A Figura 4.11 apresenta alguns exemplos de curvas Gaussianas que não proporcionaram sobreposição entre as classes em questão, exprimindo uma boa separabilidade pelo descritor. Já na Figura 4.12 ocorre sobreposição total ou parcial entre as curvas, dificultando a diferenciação entre os conjuntos expostos.

[3] Disponível em: <http://www.mathworks.com/help/images/ref/regionprops.html#bqkf8id>

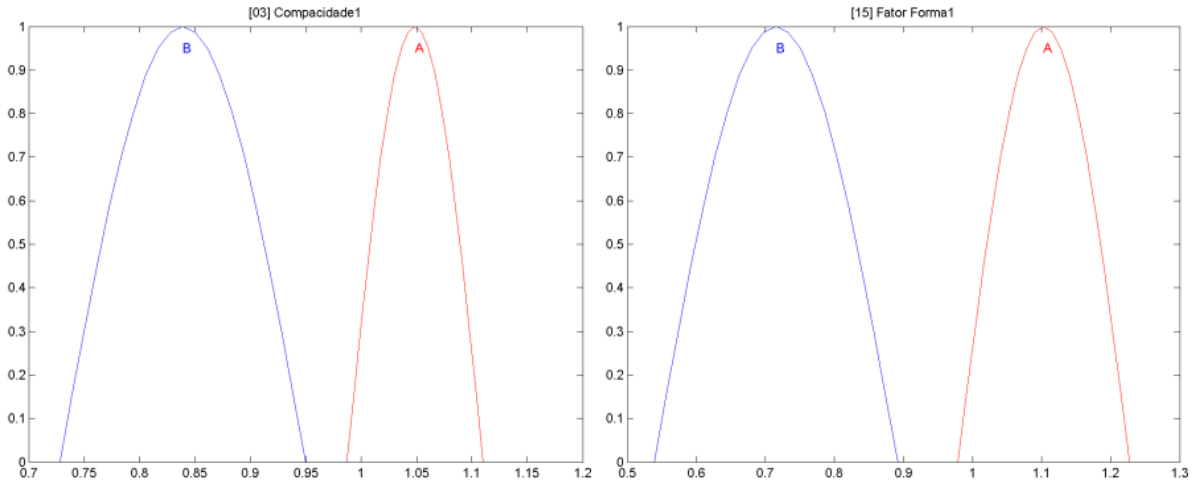

Figura 4.11 – Distribuição Gaussiana sem sobreposição das curvas

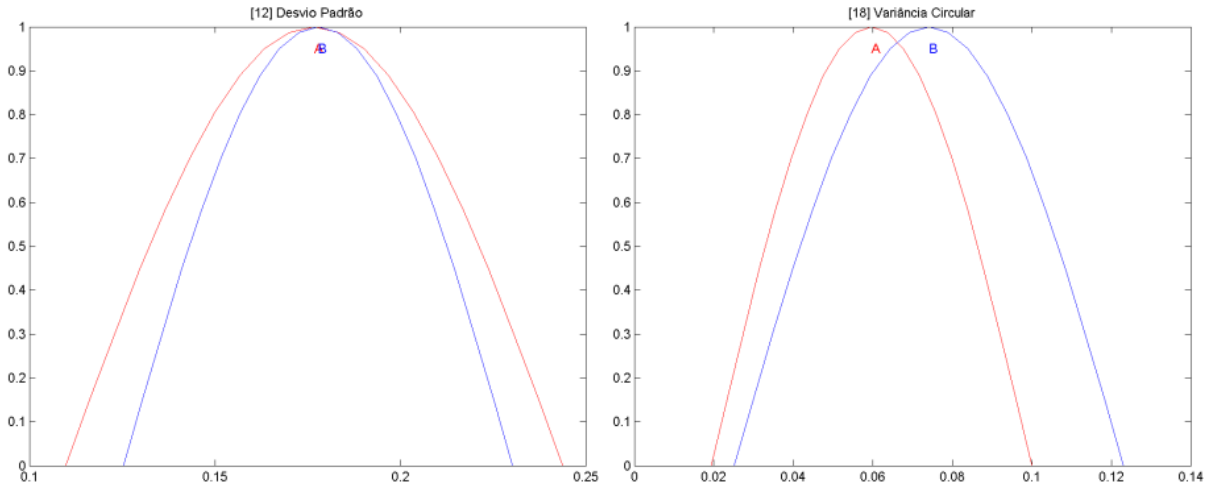

Figura 4.12 – Distribuição Gaussiana com sobreposição das curvas

As curvas obtidas com os testes foram avaliadas visualmente com base em algumas particularidades. Uma delas é quanto às intersecções, pois quanto menor a intersecção entre duas curvas, maior será a probabilidade de o atributo representar cada classe singularmente. Além da intersecção, também se analisa o eixo das abscissas, a faixa de distribuição dos valores de cada classe para o mesmo atributo, e entre aqueles selecionados, os valores entre eles. Isso evita que sejam selecionados descritores que apresentem uma mesma faixa de valores, representando uma ambiguidade de informações para a entrada da rede neural.

Outra forma de escolha das características mais significativas é por meio da seleção automática incluída no *software WEKA* versão 3.6.8, com base no método

supervisionado denominado *AttributeSelection* (WITTEN e FRANK, 2000; SILVA, 2004). A Figura 4.13 exibe o ambiente de desenvolvimento *WEKA*.

Para seu manuseio deve ser criado um arquivo com extensão ARFF ou CSV. Esse arquivo precisa conter a declaração das variáveis utilizadas e a definição das classes em que os dados serão divididos. Concluída a inicialização dos elementos, as medidas do conjunto de imagens selecionadas são incluídas. A disposição do arquivo criado é representada pela Figura 4.14.

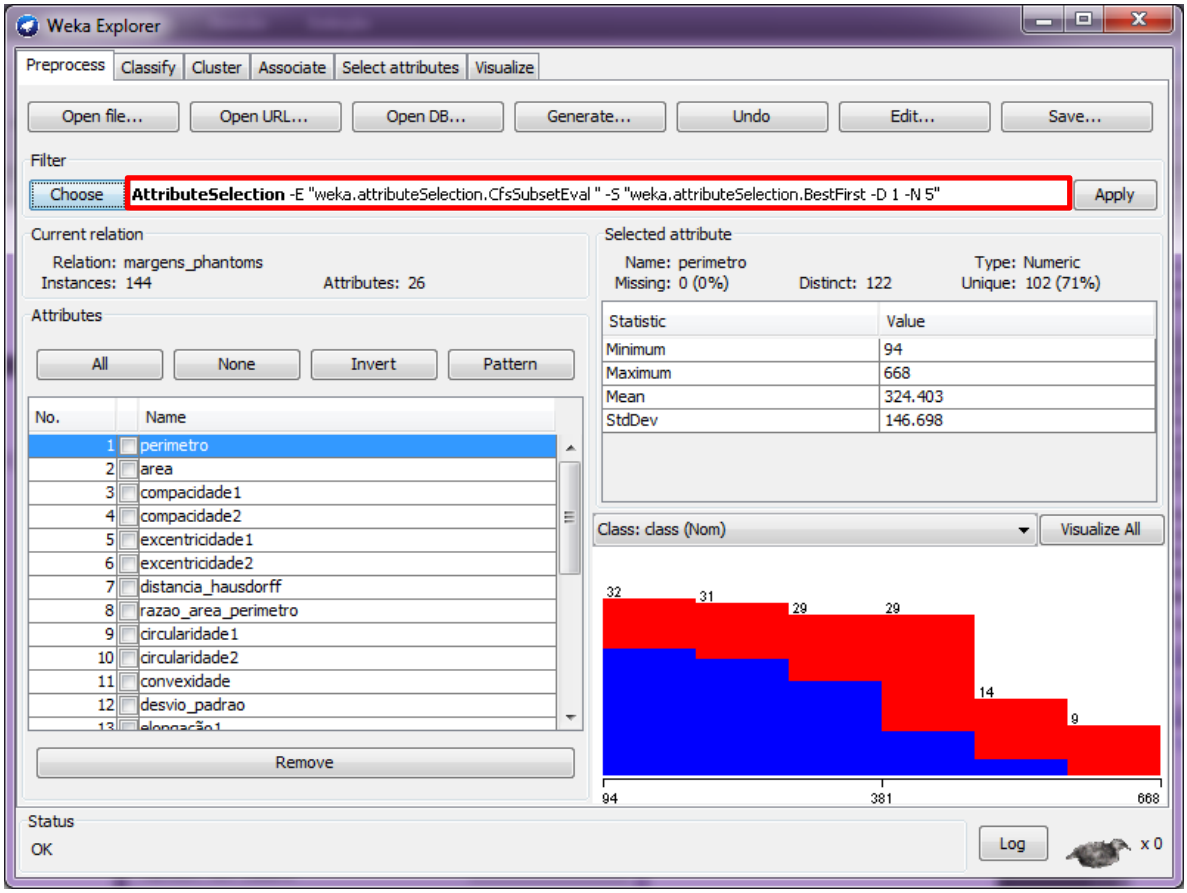

Figura 4.13 – *Software WEKA*

```
@relation classification_phantoms

@attribute perimetro numeric
@attribute area numeric
@attribute compacidade1 numeric
           .
           .
           .
@attribute razao_raio_maximo_minimo numeric
@attribute class {benigna, maligna}

@data


344.000000 11153.000000 1.088284 1.227899 0.580305 1.708846
32.421512 10.610239 0.812603 0.985465 1.088284 0.901445
0.154069 0.275229 0.784173 1.184363 7556.528853 0.044915
0.035779 0.976962 0.736123 0.165728 28.000000 0.735246
0.002907 benigna
363.000000 12154.000000 1.076609 1.292802 0.633780 1.728490
33.482094 10.841616 0.771206 0.988981 1.076609 0.878184
0.232241 0.321429 0.756757 1.159086 8016.333627 0.130663
0.059441 0.974347 0.733229 0.255047 43.000000 0.695276
0.002755 benigna
```

Figura 4.14 – Dados de entrada para o *software WEKA*

Determinados os descritores mais relevantes, esses devem ser separados dos demais. Para isso, contou-se com o auxílio da aplicação elaborada utilizando o ambiente de desenvolvimento *Borland Delphi 7*, onde todos os atributos são carregados no sistema, e em seguida, são selecionados de acordo com a escolha do usuário – podendo ser individualmente ou combinados. As características que forem selecionadas são separadas do restante e armazenadas em um novo arquivo. A Figura 4.15 exibe a aplicação destinada a agrupar apenas os descritores mais relevantes.

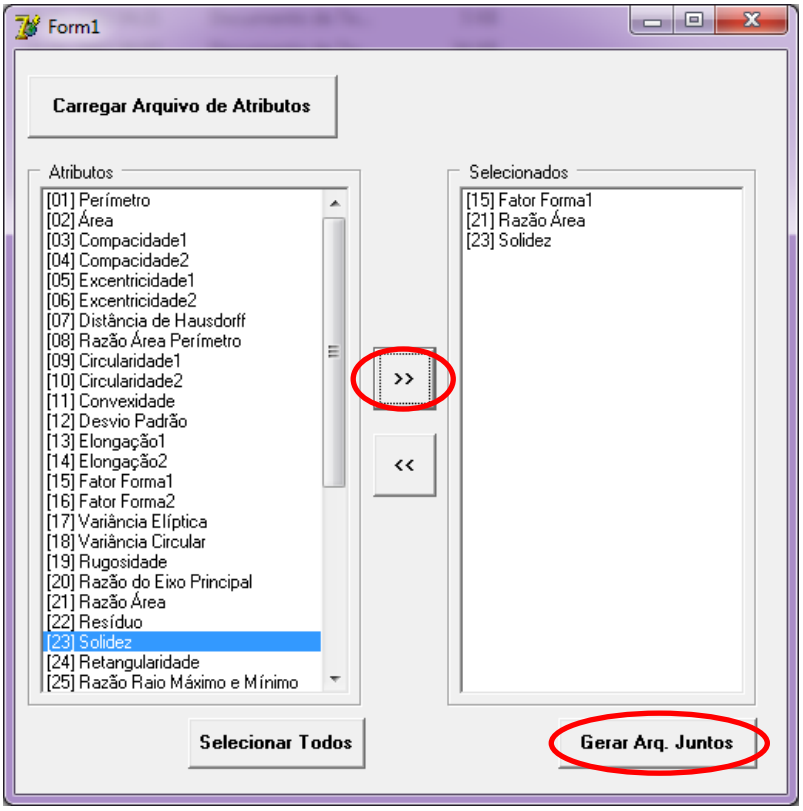

Figura 4.15 – Aplicação que une apenas os descritores mais relevantes

4.5 Classificação

Para a classificação, foi utilizada a RNA *Multilayer Perceptron* (MLP). Sua interface apresenta uma série de parâmetros a serem informados, tais como: número de camadas intermediárias, número de neurônios na camada intermediária, taxa de aprendizagem, definição do tipo de validação (*cross-validation* ou *leave one-out*), critério de parada com o erro quadrático médio menor que o estipulado e a quantidade máxima de ciclos executados. Após informados esses parâmetros, devem ser abertos e carregados no sistema os arquivos de treinamento e validação. A Figura 4.16 apresenta a rede MLP desenvolvida por Menechelli et al. (2010) utilizando o ambiente de desenvolvimento *Borland Delphi 7*, enfatizando as informações inseridas pelo usuário.

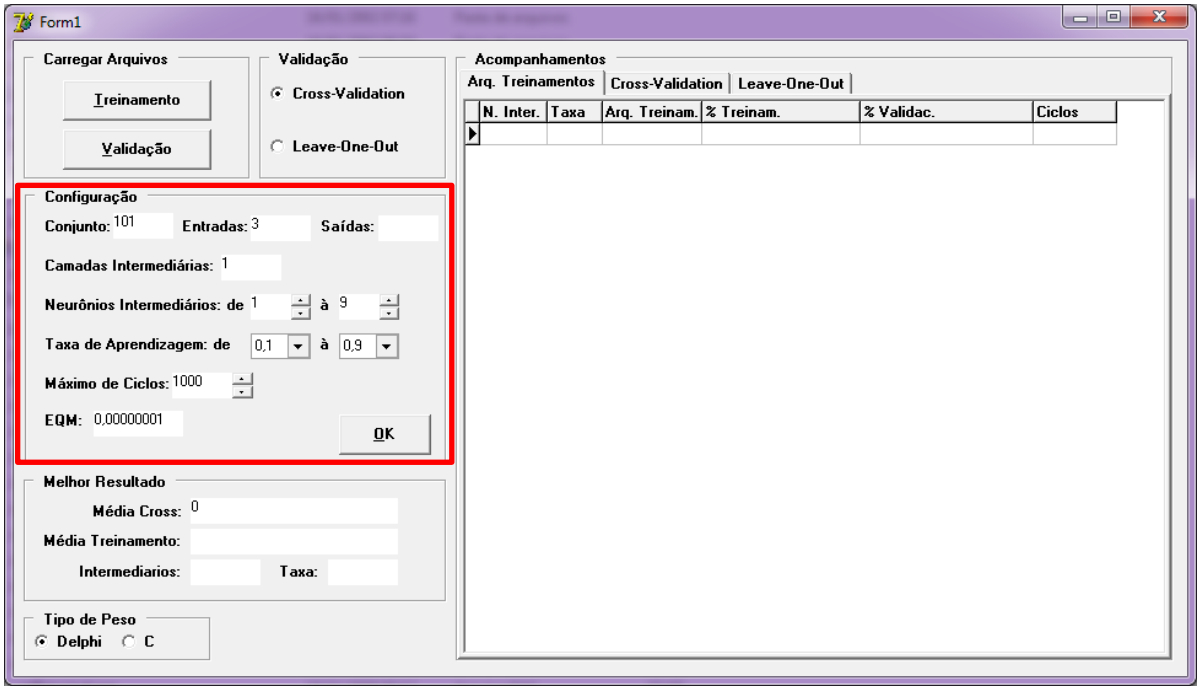

Figura 4.16 – *Multilayer Perceptron* (MLP)

Concluído o treinamento, o algoritmo terá armazenado os pesos de cada neurônio que interliga as camadas, e irá disponibilizar as informações referentes aos melhores resultados, obtidos durante a validação e treinamento, além da configuração da rede que proporcionou tais valores (quantidade de neurônios intermediários e taxa de aprendizagem), como apontado na Figura 4.17.

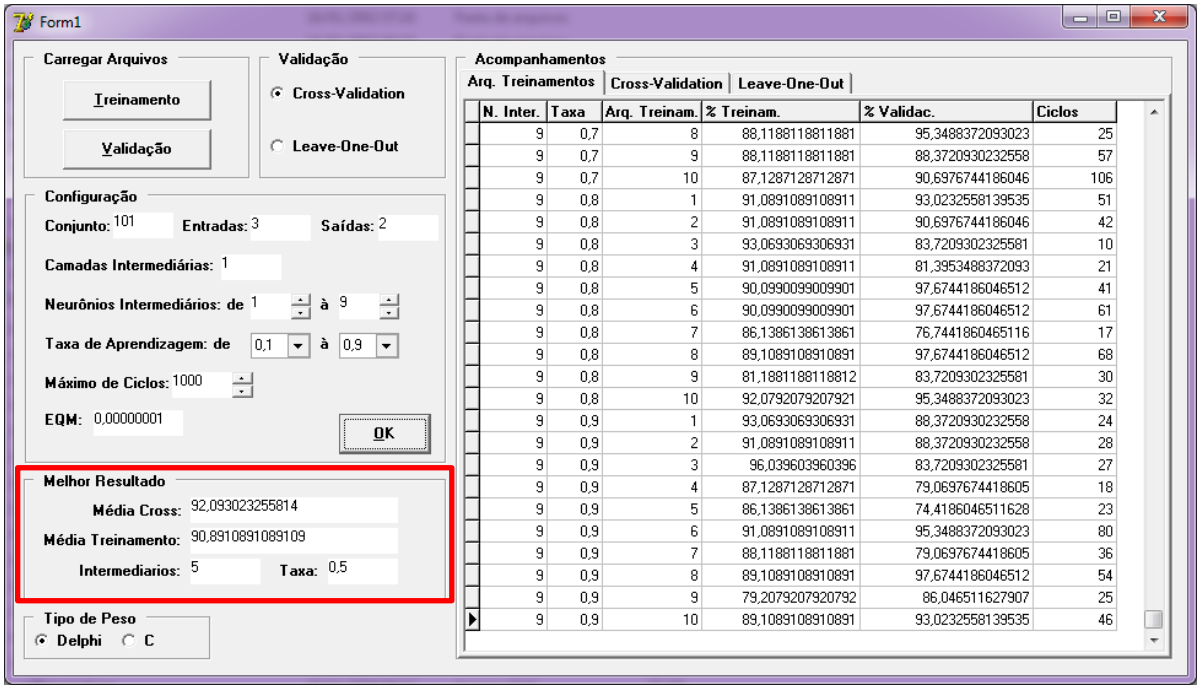

N. Inter.	Taxa	Arq. Treinam.	% Treinam.	% Validac.	Ciclos
9	0,7	8	88,1188118811881	95,3488372093023	25
9	0,7	9	88,1188118811881	88,3720930232558	57
9	0,7	10	87,1287128712871	90,6976744186046	106
9	0,8	1	91,0891089108911	93,0232558139535	51
9	0,8	2	91,0891089108911	90,6976744186046	42
9	0,8	3	93,0693069306931	83,7209302325581	10
9	0,8	4	91,0891089108911	81,3953488372093	21
9	0,8	5	90,0990099009901	97,6744186046512	41
9	0,8	6	90,0990099009901	97,6744186046512	61
9	0,8	7	86,1386138613861	76,7441860465116	17
9	0,8	8	89,1089108910891	97,6744186046512	68
9	0,8	9	81,1881188118812	83,7209302325581	30
9	0,8	10	92,0792079207921	95,3488372093023	32
9	0,9	1	93,0693069306931	88,3720930232558	24
9	0,9	2	91,0891089108911	88,3720930232558	28
9	0,9	3	96,039603960396	83,7209302325581	27
9	0,9	4	87,1287128712871	79,0697674418605	18
9	0,9	5	86,1386138613861	74,4186046511628	23
9	0,9	6	91,0891089108911	95,3488372093023	80
9	0,9	7	88,1188118811881	79,0697674418605	36
9	0,9	8	89,1089108910891	97,6744186046512	54
9	0,9	9	79,2079207920792	86,046511627907	25
9	0,9	10	89,1089108910891	93,0232558139535	46

Figura 4.17 – Treinamento da rede MLP

O algoritmo de treinamento utilizado foi o *cross-validation* (ou validação cruzada). É uma técnica utilizada para avaliar a capacidade de generalização de um modelo a partir de um conjunto de dados. O conceito central é o particionamento aleatório do conjunto de dados em subconjuntos para a estimação do resultado (dados de treinamento) e o restante do subconjunto (dados de validação ou de teste) são empregados na validação do modelo (HAYKIN, 2008).

Um total de 144 ROIs de *phantoms* ultrassonográficos da mama foi utilizado na classificação; 72 pertenciam à classe de lesões benignas e a mesma quantidade representava a classe maligna. Desse total, 70% foram destinadas ao treinamento e 30% à validação, buscando averiguar a generalização do sistema diante da apresentação de novos dados.

5 RESULTADOS E DISCUSSÕES

Os resultados aqui apresentados correspondem aos testes realizados por meio de técnicas de processamento digital de imagens e redes neurais artificiais, cuja finalidade é delimitar e classificar os achados ultrassonográficos da mama, tarefa essa de difícil interpretação pelos especialistas, devido à dificuldade na visualização e baixo contraste entre o achado ultrassonográfico e o fundo.

5.1 Banco de Imagens

Os testes primários de processamento, que compreenderam a suavização do ruído, realce do contraste e determinação do objeto, seguidos da avaliação da técnica de segmentação mais precisa, foram dirigidos a um conjunto inicial de 80 e 50 ROIs que continham algum achado suspeito, tanto em imagens simuladas quanto em ultrassonografias clínicas, respectivamente. Essas possuíam algumas características particulares muito próximas, tal como margens com certa irregularidade devido à natureza ruidosa da imagem. Isso produziu resultados

semelhantes em ambos os grupos, o que levou a empregar as mesmas técnicas de processamento.

Com o decorrer da pesquisa, o banco de imagens passou a ser expandido, sendo adquiridas mais 84 imagens de simuladores, por meio do mesmo equipamento. Já as 153 ultrassonografias clínicas constituíram-se da combinação de outros equipamentos (v. item 4.1), o que promoveu a variação na qualidade de algumas imagens, já que parte desse novo conjunto apresentava menos ruído que as habituais. Esse aspecto influenciou um pouco no processamento, mas considera-se o resultado satisfatório e apto na detecção de lesões em diferentes equipamentos de ultrassom.

Outro fator que influenciou diretamente no resultado decorreu da presença de marcações, em ultrassonografias clínicas, realizadas pelo radiologista antes do salvamento da imagem (conforme discutido no item 4.1).

5.2 Processamento Digital

O processamento de uma imagem de ultrassonografia é um desafio, além de ser a maior razão de imprecisão de muitos esquemas CAD para ultrassom. Isso ocorre devido à interferência do ruído *speckle* e imprecisão de fronteiras (XU, 2009; YAP et al., 2006). Esse fenômeno degrada significativamente sua qualidade, dificultando a discriminação de alguns detalhes.

Com a finalidade de minimizar a presença do ruído e destacar o objeto de interesse em relação ao fundo, algumas técnicas de pré-processamento foram aplicadas sobre as imagens adquiridas. Para que isso fosse possível, este trabalho contou com a experiência de uma radiologista que determinou a localização do achado ultrassonográfico e efetivou o recorte da região em que estava inserido. Esse procedimento foi executado, inicialmente, em 80 imagens simuladas e 50 ultrassonografias clínicas.

Adquiridas as ROIs, foram empregadas as seguintes técnicas de suavização e realce de contraste: o filtro de *wiener*, a equalização da imagem e o filtro da mediana, respectivamente.

A partir de resultados favoráveis em imagens simuladas, a mesma metodologia foi empregada em ROIs de ultrassonografias clínicas. Isso sucedeu

pelo fato de imagens simuladas proporcionarem maior compreensão das estruturas presentes, pois a composição e a forma do objeto em questão são conhecidas, diminuindo a subjetividade durante a interpretação.

O processo de filtragem é exibido pela Figura 5.1, que apresenta as ROIs de imagens obtidas por simuladores (dispostas à esquerda) e as procedentes de exames clínicos (à direita), bem como o resultado após a aplicação de cada uma das técnicas utilizadas durante o pré-processamento.

Ao visualizar as imagens constituintes na Figura 5.1, podemos notar que os métodos utilizados nessa pesquisa acabaram ocasionando certo borramento em suas estruturas. Contudo, a imagem de saída passou a ser representada com níveis de cinza mais uniformes, favorecendo a distinção entre o objeto de interesse e o fundo, vindo a auxiliar positivamente no reconhecimento durante as etapas subsequentes.

Concluída a fase de pré-processamento, as imagens foram submetidas a alguns algoritmos de detecção. O processo em questão transcorreu de modo totalmente automático para que fosse possível a eliminação/minimização da subjetividade visual de um observador na definição manual dos parâmetros exigidos por determinados segmentadores.

Cinco métodos foram aplicados para a execução de tal tarefa. A variação entre segmentadores selecionados tem por finalidade identificar uma metodologia que proporcionasse um resultado mais preciso possível para a representação concisa da lesão destacada.

Os ensaios foram promovidos, primeiramente, nas imagens simuladas mediante duas situações: com ausência e presença de pré-processamento. Assim, foi possível determinar a influência exercida pelos processos de filtragem abordados.

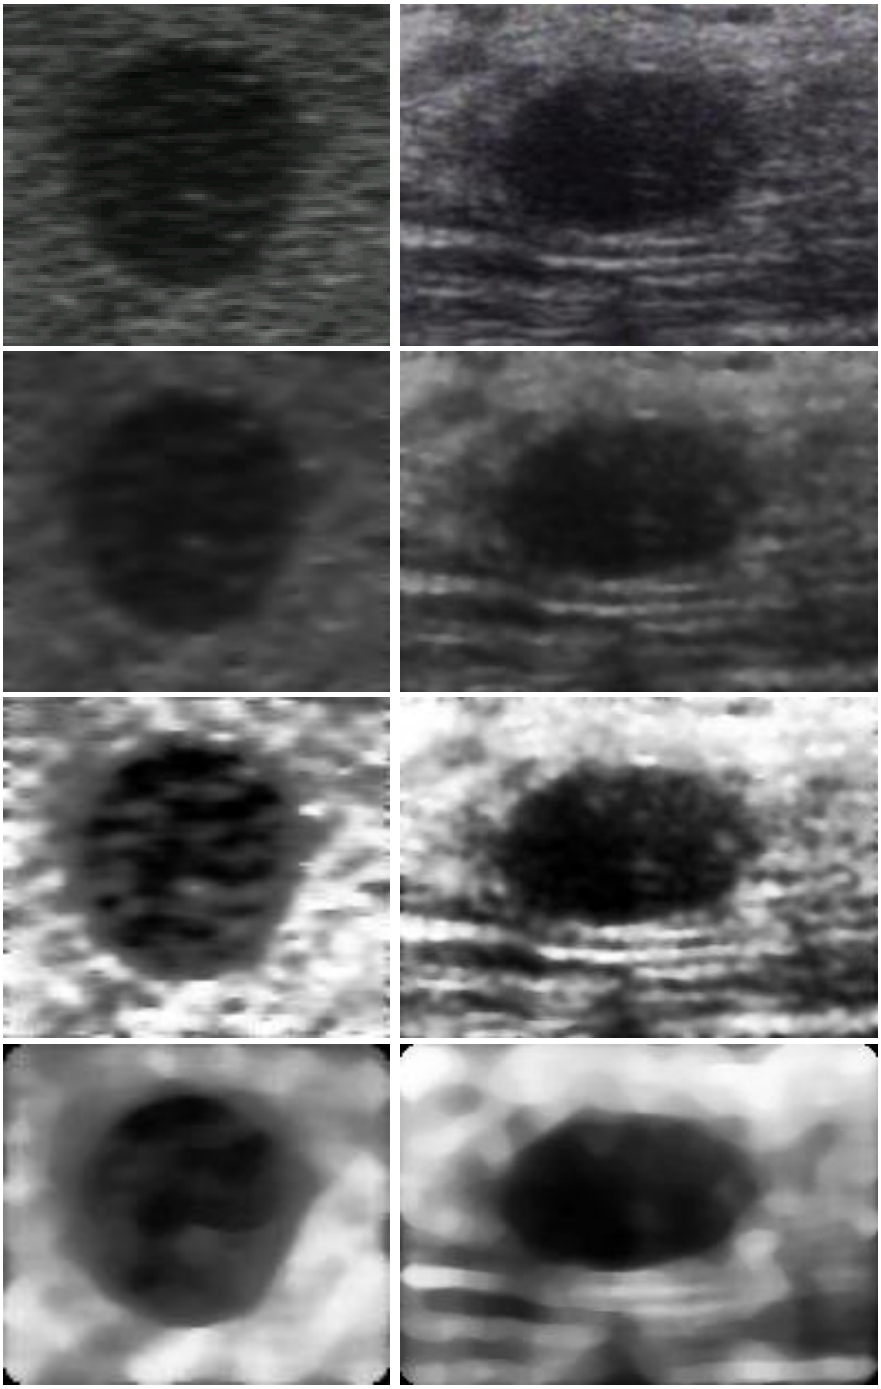

Figura 5.1 – (a) Imagem Original; (b) após a filtragem de Wiener; (c) com equalização; (d) com filtro da mediana

A segmentação, de um modo geral, foi satisfatória com a aplicação das filtragens propostas, expondo lesões com limites mais regulares e suaves, devido à minimização do ruído.

Contudo, o algoritmo de contorno ativo apresenta-se como uma exceção, cujo resultado mais significativo decorreu da ausência de qualquer processamento prévio ao segmentador. Isso fez com que não houvesse perdas de informações e nem

distorções arquiteturais. Quando a imagem era previamente filtrada, a lesão deixava de ser reconhecida pelo contorno ativo na maioria dos casos. Durante a extensão e flexão do contorno, os limites da lesão não eram encontrados por estarem mais suaves e com pouca nitidez das fronteiras. Com isso, a imagem ficou suscetível ao ruído presente em ultrassonografias, o que proporcionou irregularidades na borda da lesão, que foram representadas mais espiculadas do que realmente eram.

Em decorrência do efeito promissor em imagens simuladas, os mesmos experimentos foram desenvolvidos em ultrassonografias clínicas. O resultado dessa aplicação é exibido na Figura 5.2.

Determinada a localização e o delineamento da lesão, um algoritmo de pós-processamento foi designado para remover todas as regiões adjacentes detectadas e que não pertenciam ao objeto de interesse. Além disso, promoveu a junção dos vales internos – possíveis aberturas no interior do objeto. A imagem final passou a contar com uma única estrutura. A Figura 5.3 exibe o emprego dessa etapa nos dois conjuntos de imagens utilizados (simuladas – distribuídas à esquerda, e clínicas – à direita), em que foram removidos todos os resquícios da segmentação.

E por fim, o contorno gerado por cada técnica de segmentação foi sobreposto à ROI de entrada. Isso permitiu uma análise visual mais evidente a respeito do exato delineamento dos limites das lesões, possibilitando uma seleção mais precisa do método mais adequado para a execução dessa tarefa. Essa sobreposição, tanto em ultrassonografias adquiridas por simuladores (ordenadas à esquerda) quanto durante exames clínicos (arranjadas à direita), é exibida pela Figura 5.4.

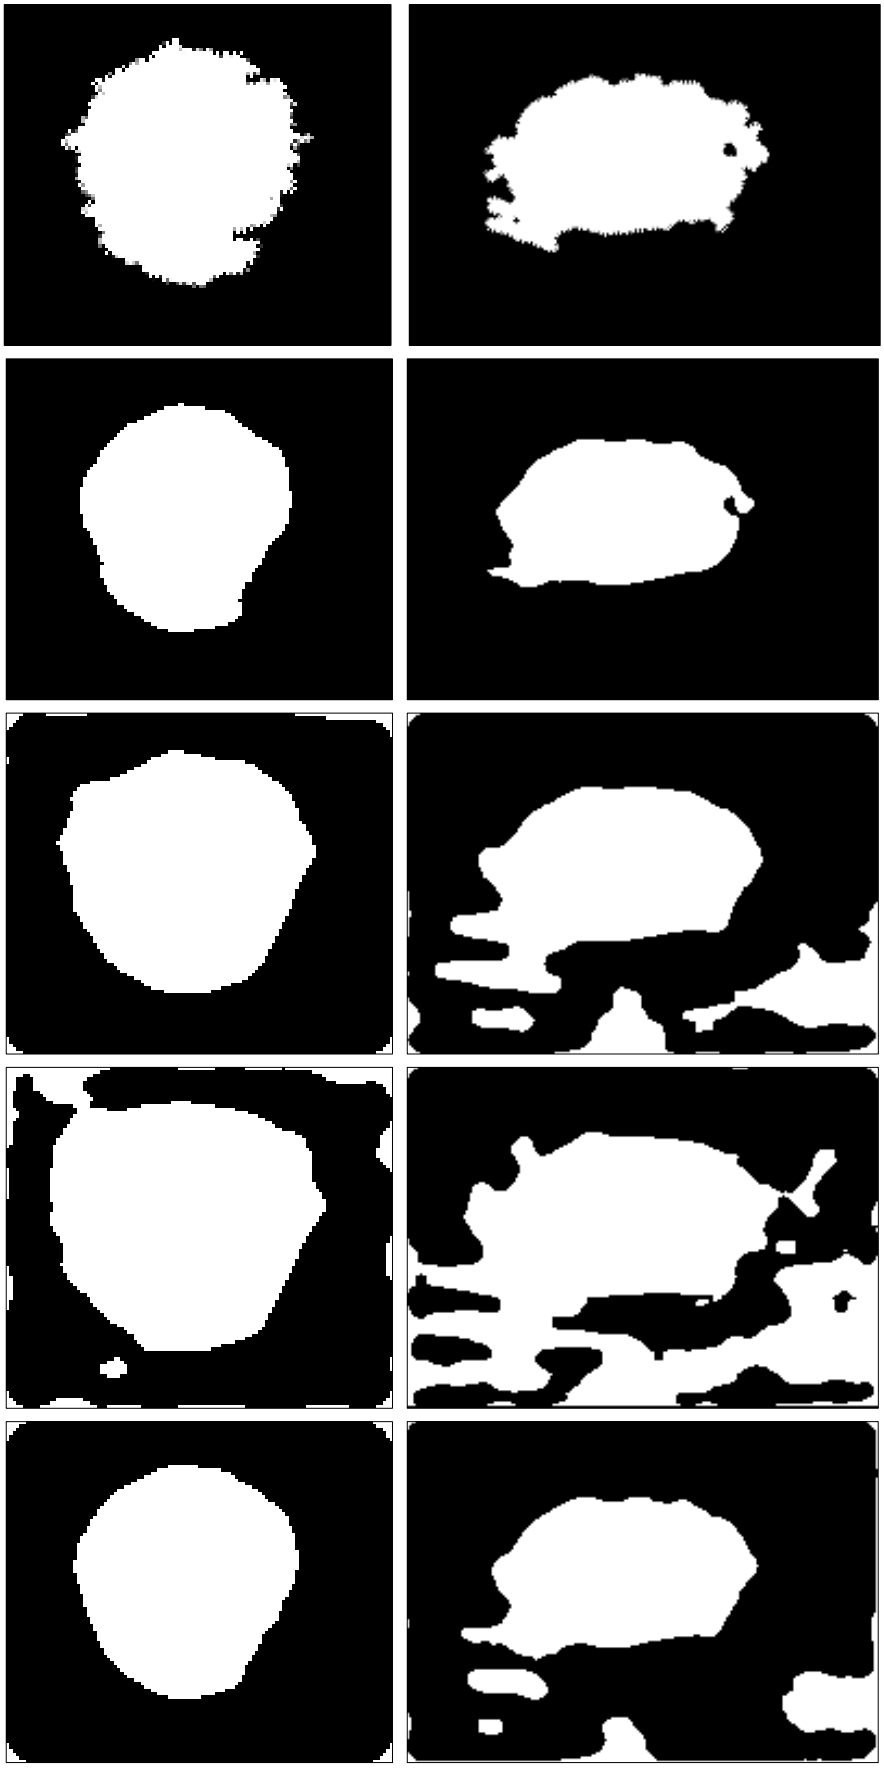

Figura 5.2 – Segmentação por (a) Contorno ativo; (b) Crescimento de região; (c) fuzzy c-means; (d) k-means; (e) SOM

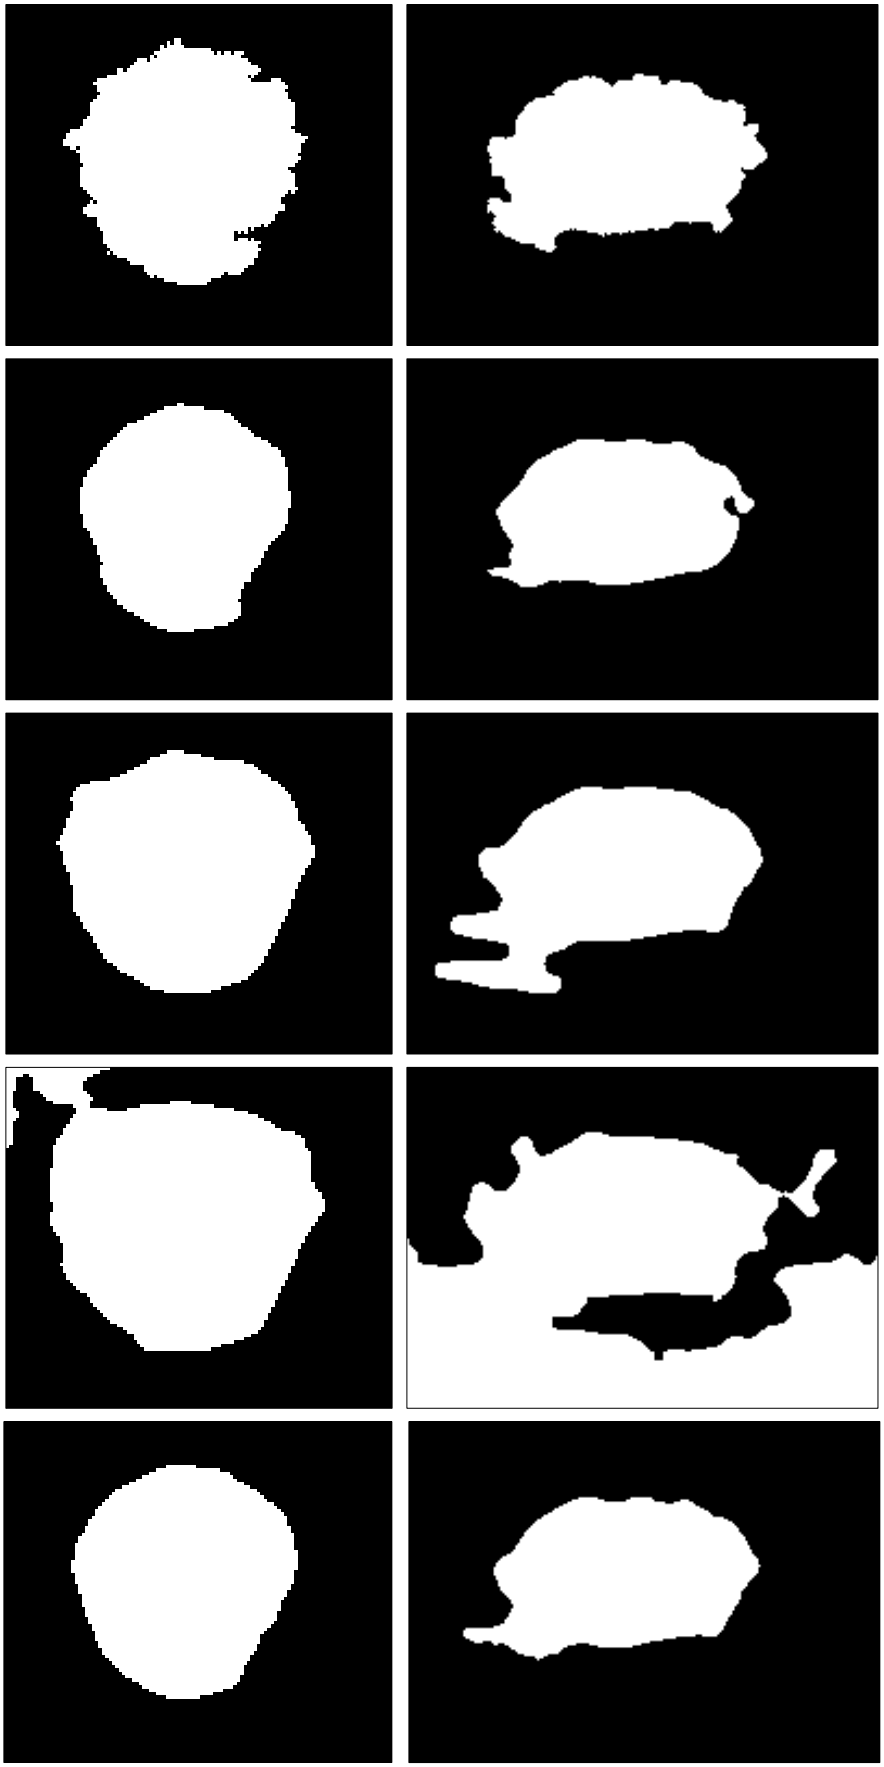

Figura 5.3 – Pós-processamento aplicado após a segmentação por (a) contorno ativo; (b) crescimento de região; (c) fuzzy c-means; (d) k-means; (e) SOM

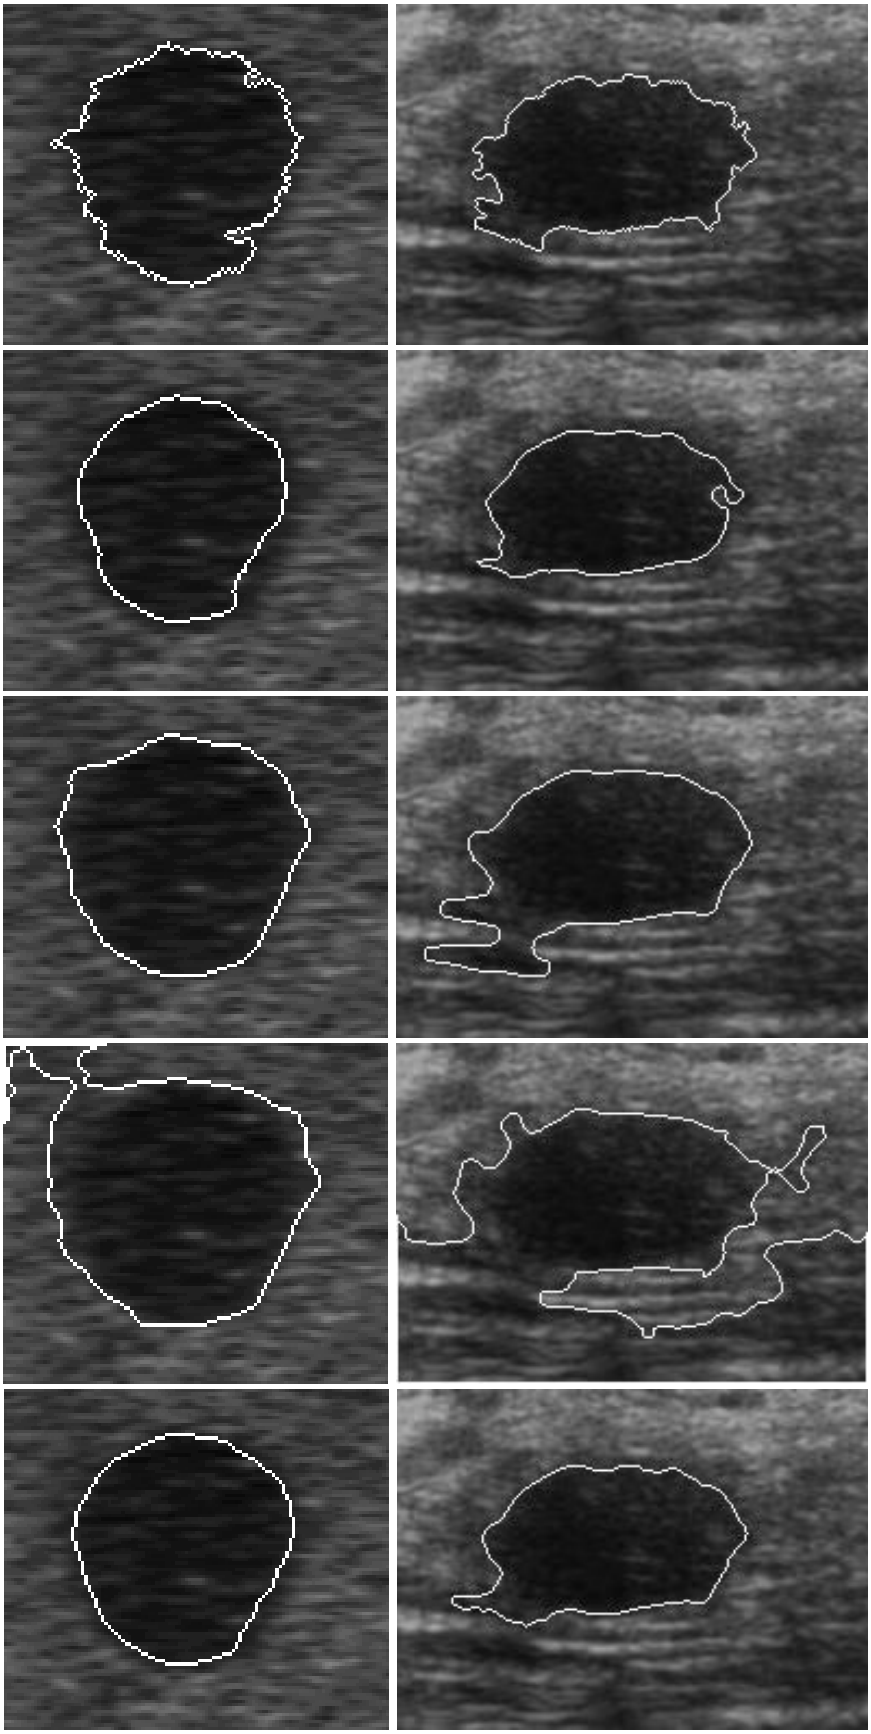

Figura 5.4 – Sobreposição do contorno à ROI original, após a segmentação, por (a) contorno ativo; (b) crescimento de região; (c) fuzzy c-means; (d) k-means; (e) SOM

5.3 Validação

Mediante a subjetividade visual e dependência constante de um observador na seleção da técnica de segmentação mais precisa para determinar os limites da lesão, foram estudados métodos que quantificassem a proximidade entre a demarcação manual, proporcionada por uma radiologista experiente, e a automática, fornecida pelos segmentadores.

Para que isso fosse possível, foi utilizado um total de 80 imagens simuladas e 50 ultrassonografias clínicas, nas quais uma radiologista determinou manualmente o contorno, e a partir dele foi produzida sua área, como apresentado Figura 5.5.

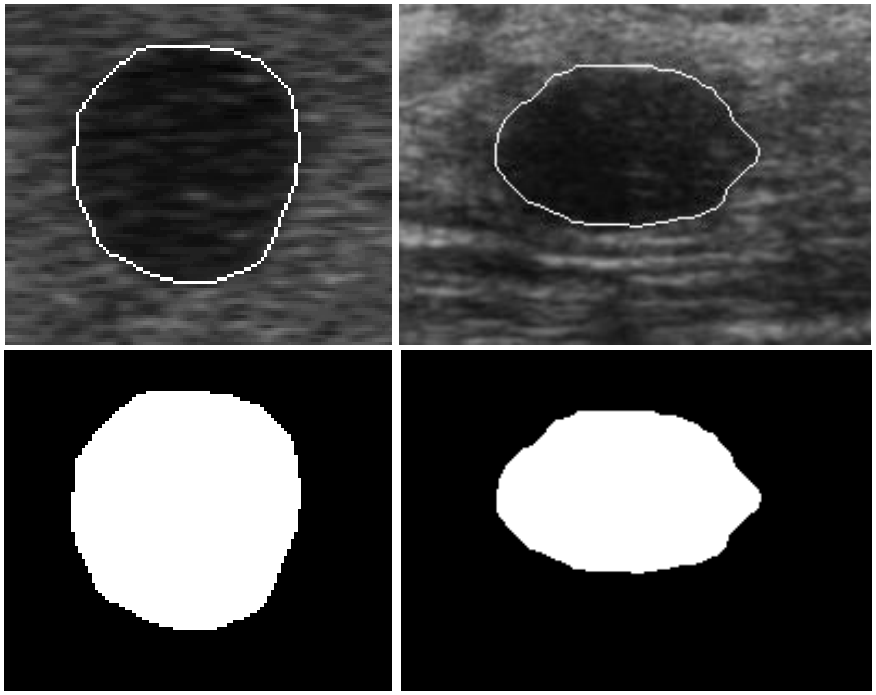

Figura 5.5 – (a) Delimitação manual da lesão por um radiologista e (b) extração da área da lesão

A área obtida pelo delineamento da radiologista foi comparada com a produzida por cada uma das 5 técnicas de segmentação previamente descritas. Foram então originados diversos valores para descrever quantitativamente a taxa de acerto e erro quanto à representação proporcionada por cada segmentador. O resultado de tal comparativo, em imagens simuladas, é apresentado na Tabela 5.1.

Tabela 5.1 – Métricas de avaliação aplicadas em imagens simuladas quanto às cinco técnicas de segmentação

	AOM (%)	AUM (%)	AVM (%)	CM (%)	RVP (%)	VPP (%)	Q (%)	A (%)	Err (%)	RFP (%)
Contorno Ativo	77.96	18.47	4.58	84.54	81.52	94.14	77.96	92.78	7.21	2.65
Cresc. Região	75.02	22.50	3.23	83.09	77.49	96.76	75.02	91.51	8.48	1.06
Fuzzy C-Means	72.38	19.75	18.51	78.03	80.24	81.48	72.38	87.81	12.18	8.02
***K*-Means**	60.73	9.72	36.78	71.41	90.27	63.21	60.73	77.63	22.36	27.69
SOM	82.50	13.17	5.17	88.05	86.82	94.82	82.50	94.32	5.67	2.02
Valor Requerido	100	0	0	100	100	100	100	100	0	0

Concluídos os testes de processamento em imagens simuladas e atingidos resultados satisfatórios, as mesmas medidas foram aplicadas em ultrassonografias clínicas, cuja finalidade era verificar se os dados proporcionados em simuladores eram condizentes aos casos reais. Os valores obtidos são exibidos na Tabela 5.2.

Tabela 5.2 – Métricas de avaliação aplicadas em imagens clínicas quanto às cinco técnicas de segmentação

	AOM (%)	AUM (%)	AVM (%)	CM (%)	RVP (%)	VPP (%)	Q (%)	A (%)	Err (%)	RFP (%)
Contorno Ativo	75.84	17.65	15.61	93.90	72.60	93.94	68.24	91.77	8.23	2.36
Cresc. Região	70.85	19.42	25.55	93.22	67.13	92.07	62.32	89.79	10.21	2.19
Fuzzy C-Means	59.86	24.51	33.63	71.96	77.41	72.84	57.36	85.19	14.81	10.87
***K*-Means**	38.92	30.74	57.02	42.26	87.65	45.65	41.61	67.29	32.71	37.89
SOM	75.25	19.75	24.09	93.97	67.46	96.77	65.15	91.33	8.66	0.62
Valor Requerido	100	0	0	100	100	100	100	100	0	0

Com base nos dados expostos, é possível destacar a superioridade da segmentação por contorno ativo e pela rede neural SOM em relação às demais. Essas, quando comparadas à delimitação proporcionada pelo radiologista, foram as que mais se aproximaram e ofereceram menores taxas de erro em sua representação, bem como os percentuais mais altos referentes à acurácia.

Como a técnica de contorno ativo ofereceu limites mais irregulares, tendendo, erroneamente, à malignidade em certas lesões, foi escolhida a segmentação por meio da rede neural SOM, a qual proporcionou bordas suaves, representando melhor o objeto.

5.4 Seleção de Características

Dentre as 25 características morfológicas extraídas das imagens simuladas, foram selecionadas as mais relevantes por meio de curvas Gaussianas e com auxílio do método *AttributeSelection*, inserido no *software WEKA*.

O processo de seleção de características teve início com a produção de 25 curvas de distribuições de gaussianas. A partir daí, seguiram as comparações, cuja finalidade era separar as curvas que não produziram bons resultados, pois muitas de suas áreas acabaram se sobrepondo total ou parcialmente, tais como as apresentadas na Figura 5.6. Essas curvas dificultam a separação entre as categorias benignas e malignas pelo classificador, pois representam descritores que não auxiliaram na distinção adequada, e devem ser removidos do processo de classificação.

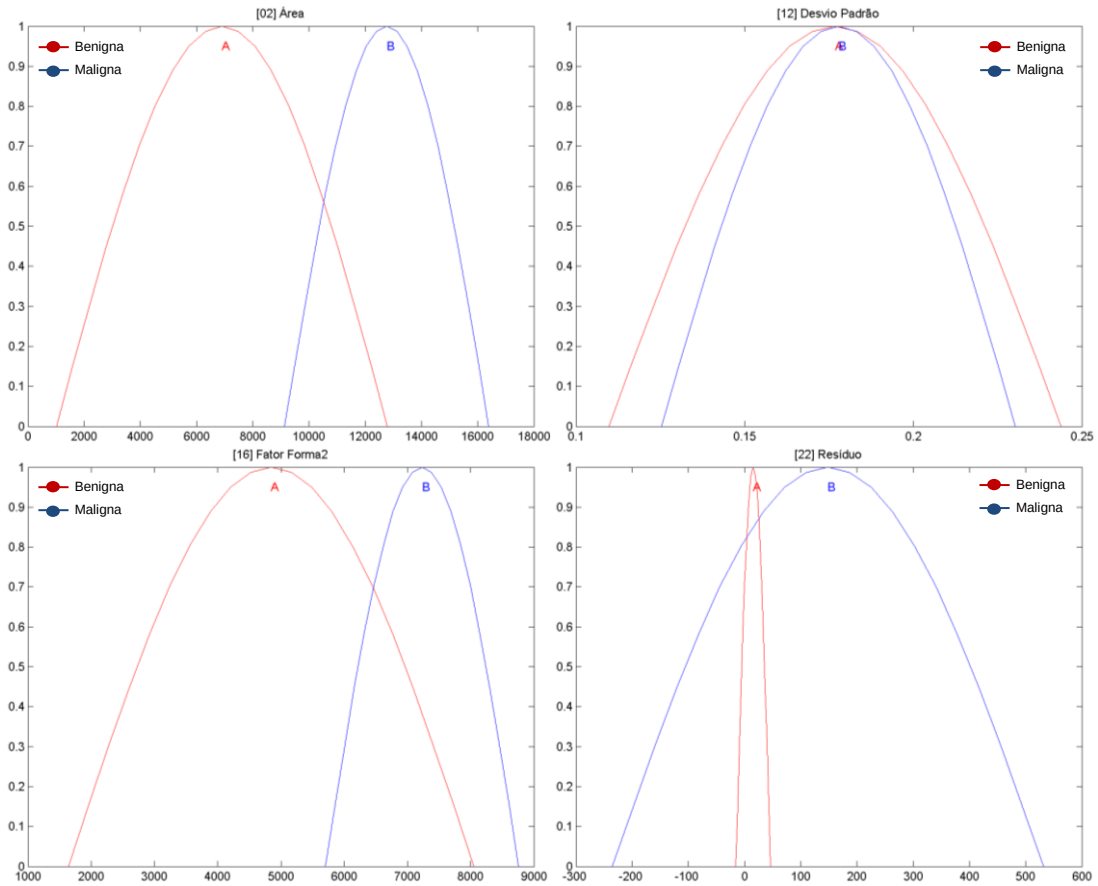

Figura 5.6 – Algumas distribuições Gaussianas que não produziram bons resultados

Desse modo, oito distribuições Gaussianas proporcionaram bons resultados, ou seja, as bases das curvas não se sobrepuseram ou possuíam baixa área de

ocorrência. Os descritores envolvidos são: perímetro, compacidade (apresentado por MINGGIANG et al., 2008), circularidade (proposta por Zhang e Lu, 2004), convexidade, fator forma (formulado por Russ, 1995), razão área, solidez e retangularidade, conforme apresentado na Figura 5.7.

Outra forma de seleção dos atributos mais significativos, testada no presente trabalho, dá-se por meio do *software WEKA*, o qual disponibiliza seu próprio seletor automático, denominado *AttributeSelection*. A Figura 5.8 exibe a interface do *software* e o resultado da seleção. Por meio deste, foram também escolhidas oito características, sendo elas: perímetro, compacidade (exposto por MINGGIANG et al., 2008), circularidade – tanto a proposta por Zhang e Lu (2004) quanto a descrita por Yap et al. (2009), fator forma (exposta por Russ, 1995), razão do eixo principal, solidez e razão de área.

A Tabela 5.3 traz os oito atributos mais relevantes que foram selecionados por cada um dos métodos utilizados para tal finalidade. Podemos notar que seis das oito características são comuns, distinguindo apenas quanto às duas últimas, que são: retangularidade e convexidade – selecionadas pela distribuição Gaussiana; e circularidade (com a formulação de Yap et al., 2009) e razão do eixo principal – destacada pelo *AttributeSelection*.

Tabela 5.3 – Descritores mais relevantes

Distribuição Gaussiana	***AttributeSelection***
Perímetro	Perímetro
Compacidade[1]	Compacidade[1]
Razão de Área	Razão de Área
Solidez	Solidez
Fator Forma	Fator Forma
Circularidade[1]	Circularidade[1]
Retangularidade	Circularidade[2]
Convexidade	Razão do Eixo Principal

Dessa forma, é possível certificar a consistência dos seletores abordados, os quais apontaram, em sua grande maioria, a igualdade no produto final. Além disso, obteve-se maior confiabilidade em relação aos dados que iriam servir de entrada para o classificador neural.

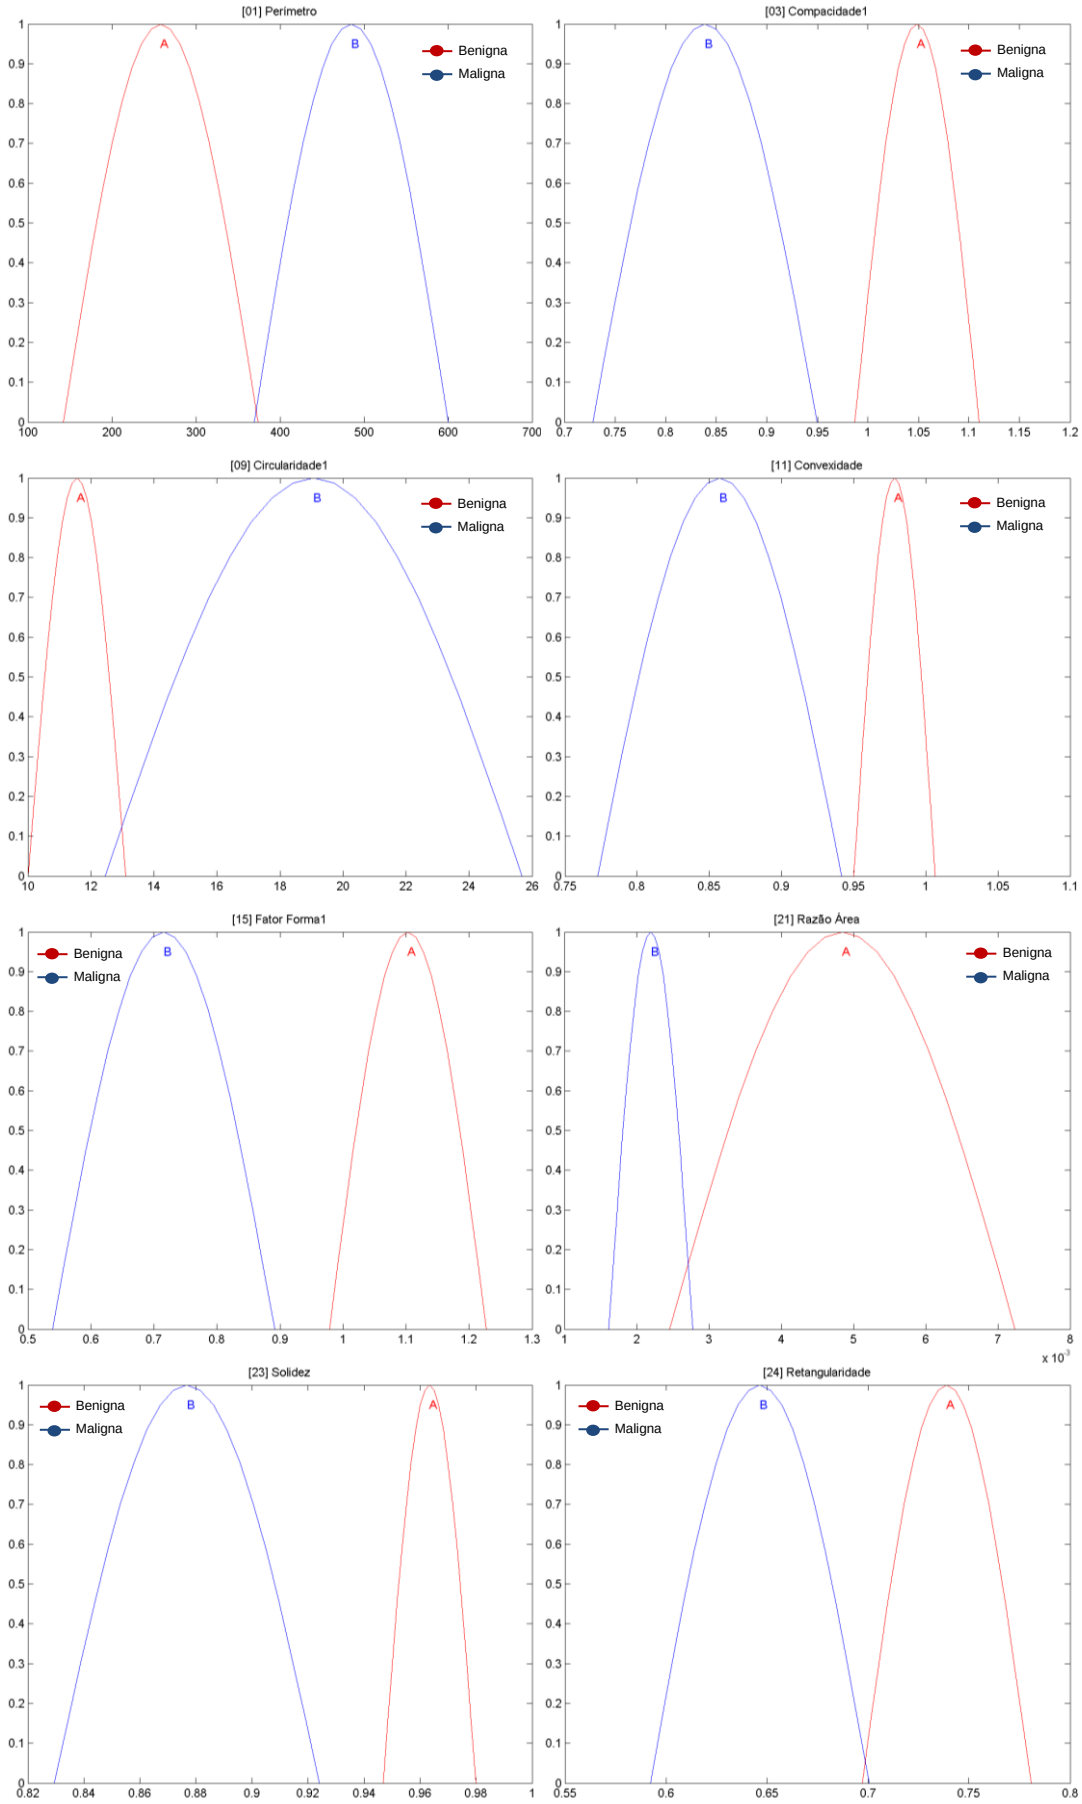

Figura 5.7 – Distribuições gaussianas que produziram bons resultados

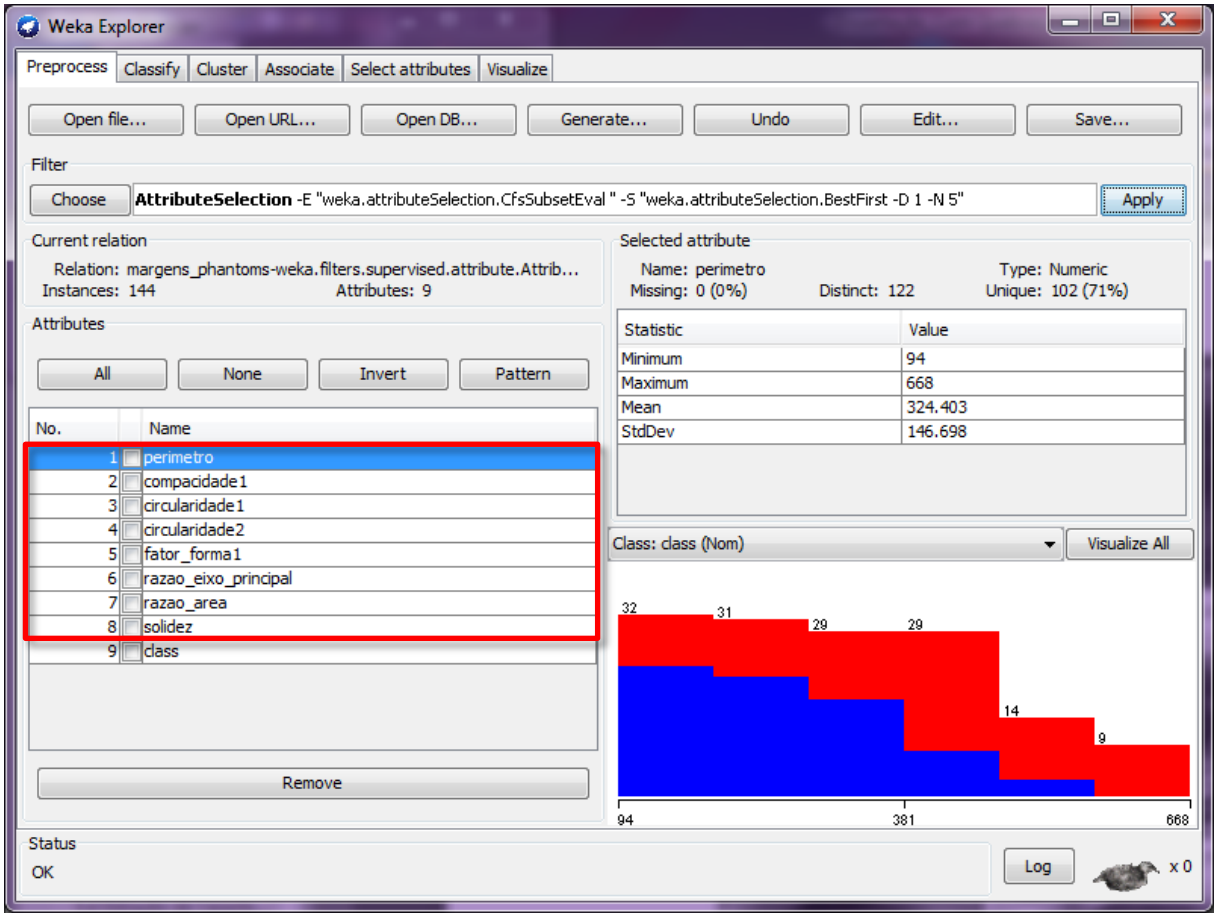

Figura 5.8 – Seletor de características do *Weka – AttributeSelection*

5.5 Classificação

Inicialmente foram utilizadas 144 imagens simuladas, com 72 em cada classe (benignas e malignas). Os testes de classificação foram promovidos com base na escolha dos descritores mais relevantes, selecionados tanto por curvas de distribuição Gaussiana quanto pelo *AttributeSelection* (v. item 5.4).

Alguns treinamentos foram realizados com as características selecionadas pelo *AttributeSelection*. Contudo, as características Circularidade2[4] e razão do eixo principal, quando serviam de entrada para o classificador neural MLP, separadas ou combinadas com os outros descritores, não atingiram bons índices de desempenho, e por isso, foram descartadas.

Em virtude disso, serviram de entrada para o classificador apenas as 8 características mais relevantes eleitas pela distribuição gaussiana. Esses descritores

[4] Proposta por: Yap et al. (2009)

foram apresentados individualmente à MLP, que, porém, não alcançou resultados muito expressivos, mesmo para as curvas que, aparentemente, representavam maior separação entre as classes.

Por isso, foram promovidos múltiplos ensaios com a união/combinação dos 8 descritores, decorrentes da análise combinatória sem repetição, o que resultou em 247 possibilidades de entradas para o treinamento da rede MLP, além das 8 decorrentes da submissão individual de cada descritor. Os treinamentos passaram por intensivos testes, mediante a alteração na configuração topológica da rede. Sua única camada intermediária teve seus neurônios variando de 1 a 9, com taxa de aprendizagem constantemente modificada entre os índices 0,1 a 0,9.

Os dados das 144 imagens foram separados em 20 conjuntos, selecionados aleatoriamente, em que 10 fazem parte do treinamento, totalizando 50 elementos por classe, e 10 para a validação, resultando nos 22 elementos por classe.

O resultado mais expressivo foi proporcionado pela união dos descritores: fator forma, razão de área e solidez, configurando as 3 entradas da MLP. Quando associados, a classificação alcançou um percentual de 94,2% de acerto na validação cruzada. Quanto à topologia que determinou esse valor compreendeu 2 neurônios na camada intermediária e taxa de aprendizagem igual a 0,5.

Concluída a classificação, foram levantados os elementos que compõem a tabela de contingência, como exibido na Tabela 4.1.

Tabela 5.4 – Resultado do treinamento pela rede MLP

Classes		**MLP**				
		Acerto por Classe				**Az**
Benignas	**Malignas**	**VP**	**FN**	**FP**	**VN**	
72	72	68	4	7	65	0,92

A partir desses, puderam ser aferidos os valores relativos à sensibilidade (casos de VP em pacientes que possuem a doença) e especificidade (ocorrência de VN em paciente que não portam a doença) que, quando combinados, permitem a avaliação do desempenho do classificador por meio da curva ROC. A Figura 5.9 retrata a curva ROC (EVANS, 1981) obtida a partir do melhor treinamento da MLP em imagens simuladas. Já para sumarizar a qualidade da curva, foi calculada a área sob ela (Az), resultando em 0,92.

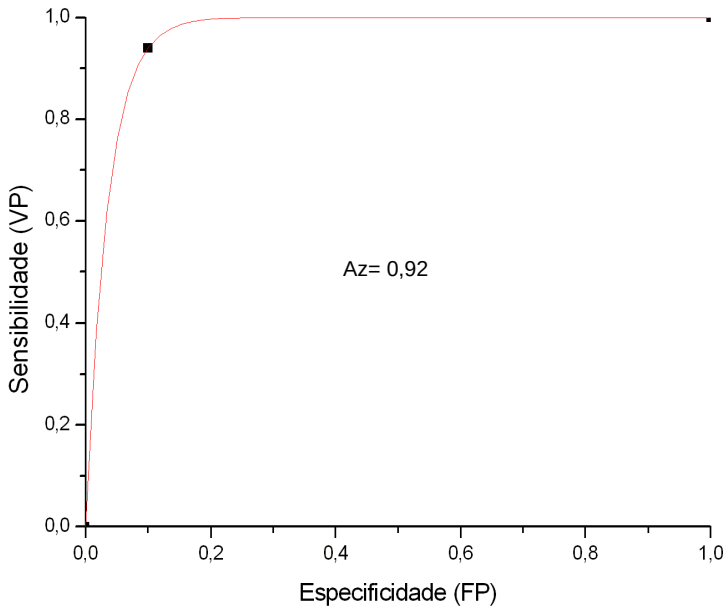

Figura 5.9 – Curva ROC adquirida a partir da melhor classificação da MLP

Com base na eficiência na classificação das lesões presentes nos simuladores, decidiu-se verificar a generalização do classificador com a apresentação de imagens desconhecidas, ou seja, que não foram utilizadas durante o treinamento e nem na classificação. Para isso, o sistema recebeu 40 novas imagens de *phantoms* (24 benignas e 16 malignas) a fim de promover a classificação dessas. Os valores atingidos seguem resumidos na Tabela 5.5.

Tabela 5.5 – Resultado da classificação em imagens simuladas

Classes		**MLP**				
		Acerto por Classe				**Az**
Benignas	**Malignas**	**VP**	**FN**	**FP**	**VN**	
24	16	16	0	4	20	0,92

Podemos destacar o baixo número de casos FP e a ausência de FN, proporcionando uma sensibilidade de 100% e especificidade de 83,3% (com 16,7% de casos FP). A partir desses índices foi avaliado o desempenho do classificador com base na área sob a curva ROC, que resultou em um Az de 0,92, como apresentado na Figura 5.10, na qual é mostrada a curva ROC das imagens classificadas pelo sistema proposto. Se levarmos em consideração a acurácia do sistema, o percentual atingido foi de 90%.

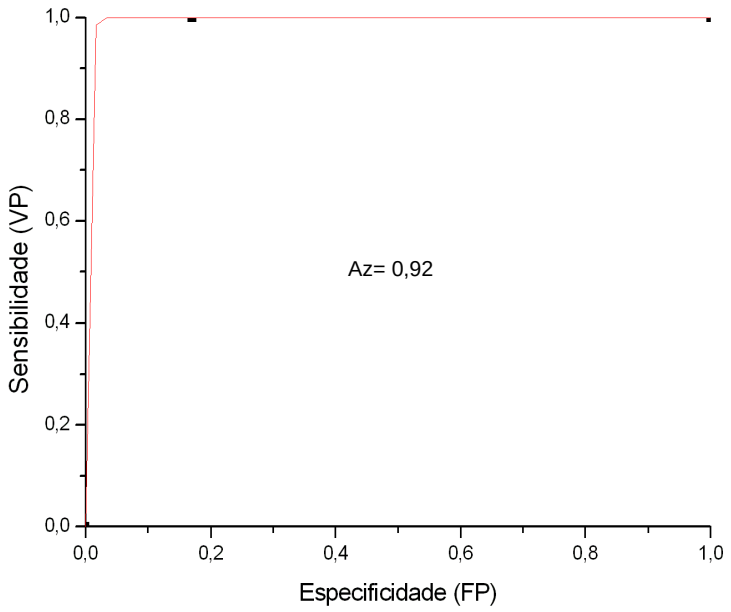

Figura 5.10 – Curva ROC da classificação em imagens simuladas

Concluídos os ensaios com *phantoms*, passou a ser investigada a classificação em ultrassonografias clínicas da mama. Entretanto, o grande problema foi decorrente da baixa quantidade de imagens e também pela carência das que sugerem maior atenção, por apresentar lesões com aspectos malignos. Assim, não foi possível a execução de novo treinamento neural com as ultrassonografias clínicas. Diante disso, as ultrassonografias clínicas foram submetidas ao sistema, sob as mesmas condições dos simuladores. A especialista recortou 173 ROIs, que foram segmentadas automaticamente. Em seguida, foram extraídas as medidas de solidez, razão de área e fator forma de cada ROI. Por fim, esses dados serviram de entrada para o classificador neural MLP, a partir do treinamento em imagens de *phantoms*. Os resultados adquiridos com ultrassonografias clínicas são retratados na Tabela 5.6.

Tabela 5.6 – Resultado da classificação em imagens clínicas

Classes		**MLP**				
		Acerto por Classe				**Az**
Benignas	**Malignas**	**VP**	**FN**	**FP**	**VN**	
150	23	23	0	33	117	0,89

O elevado índice de casos FP está, em grande parte, relacionado a algumas diferenças morfológicas entre as imagens simuladas e as clínicas. A grande maioria das imagens de *phantoms*, que sugerem a benignidade da lesão, possuía forma

arredondada, influenciando diretamente os descritores de características e, consequentemente, a classificação. Já se tratando das imagens clínicas, muitas delas apresentavam forma mais alongada e, ao serem avaliadas com base no resultado obtido pelo treinamento em imagens simuladas, passavam a ser consideradas malignas. A Figura 5.11 indica um exemplo da diferença morfológica entre (a) imagens simuladas e (b) clínicas, presente na maioria das imagens benignas.

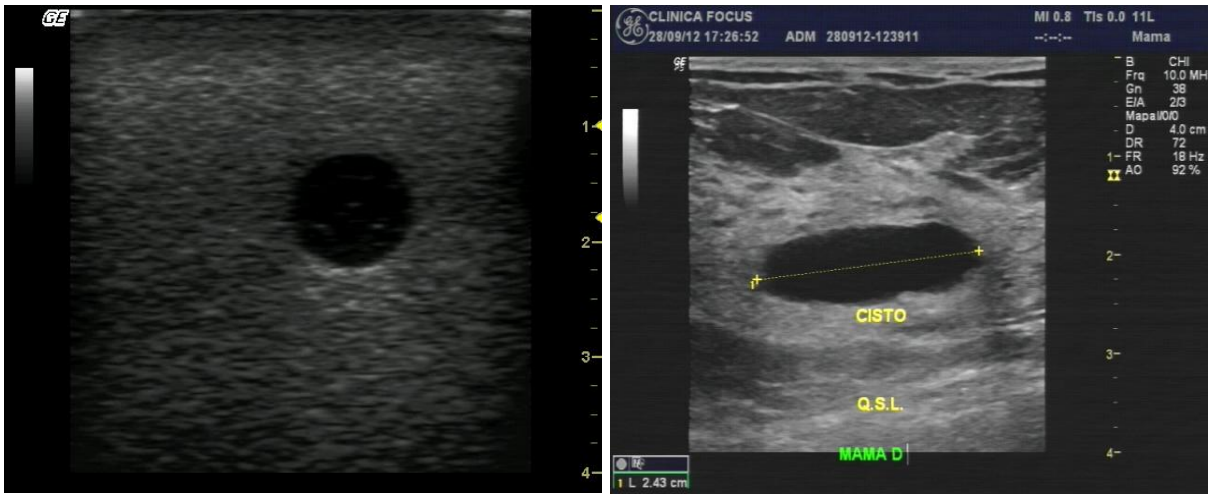

Figura 5.11 – Exemplo da diferença morfológica entre as imagens simuladas clínicas

Mesmo diante de pequenas diferenças na morfologia das lesões simuladas e clínicas, considera-se que o classificador atingiu uma boa generalização dos dados, atingindo uma sensibilidade de 100% e especificidade de 78%, devido a 22% de casos FP. A Figura 5.12 demonstra a atuação do classificador aferida por meio da área sob a curva ROC, cujo Az resultou em 0,89. Para esta circunstância, obtivemos uma acurácia de 81%.

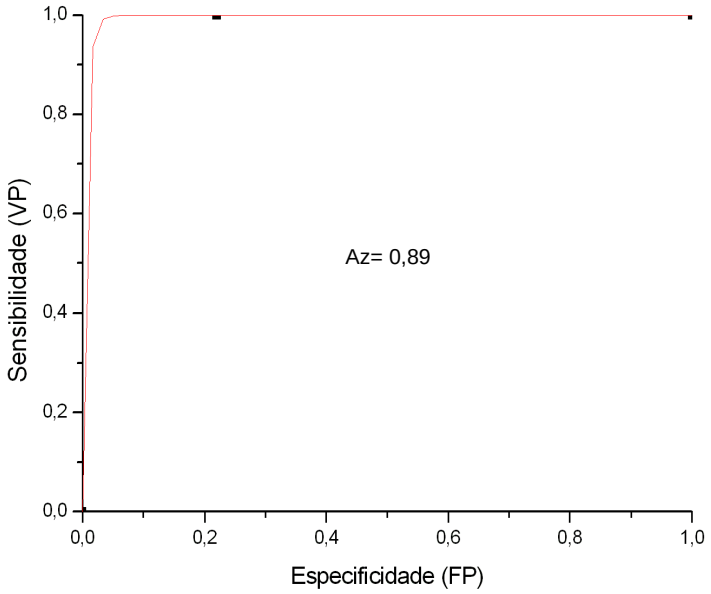

Figura 5.12 – Curva ROC da classificação em imagens clínicas

5.6 Observações

Um dos grandes diferenciais em imagens de ultrassom é decorrente da presença do reforço acústico posterior. Esse fenômeno se manifesta como uma faixa mais clara posterior a uma estrutura líquida, sendo evidente a mudança na intensidade de cinza. Na Figura 5.13 é possível observar esse artefato em uma imagem obtida por simuladores.

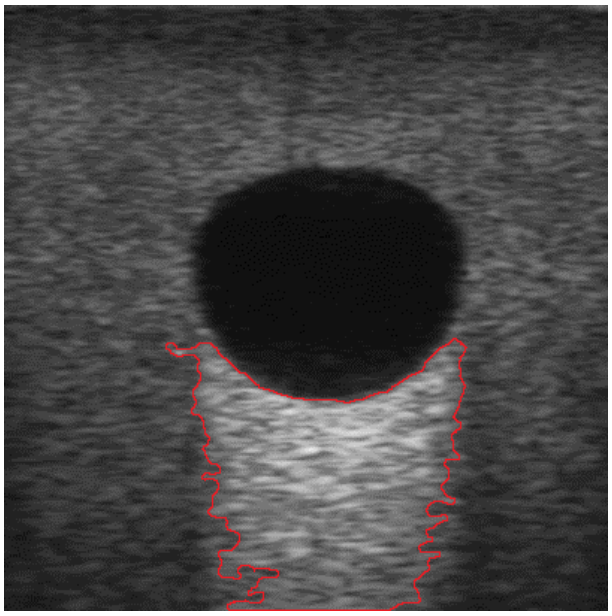

Figura 5.13 – Imagem simulada com reforço acústico

Esse efeito auxilia substancialmente na diferenciação entre cistos (cheios de líquido) e massas sólidas, revelando fortemente o caráter de benignidade do achado ultrassonográfico. Sua presença não prejudica a segmentação, pois nestes casos trata-se de lesões anecóicas, cujas fronteiras são claramente definidas, o que facilita o processo de detecção. A Figura 5.14 denota a detecção, por meio da rede SOM, de uma lesão introduzida em uma imagem de *phantom*, na qual é manifestada a presença de reforço acústico.

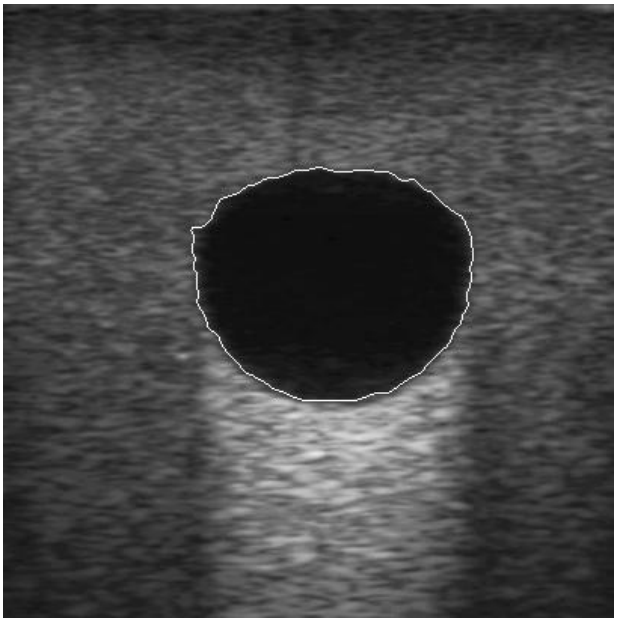

Figura 5.14 – Segmentação da imagem simulada com a presença de reforço acústico

O ultrassom produz também um artefato denominado sombra acústica. É o resultado da produção de uma área escura localizada na parte posterior a um meio/estrutura altamente atenuante, gerando uma zona de penumbra em órgãos mais profundos, como pode ser visto na Figura 5.15. Imagens desse tipo instigam maior atenção por parte dos especialistas, pois apresentam forte tendência à malignidade.

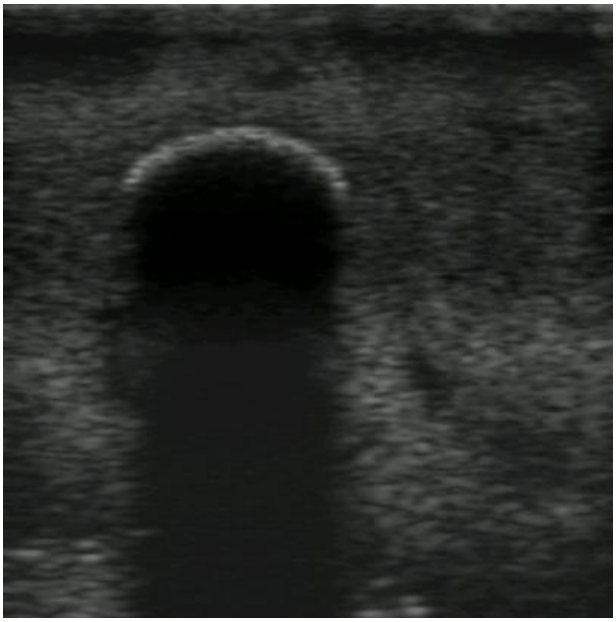

Figura 5.15 – Imagem simulada com sombreamento acústico

A segmentação é dificultada em consequência da presença do sombreamento, pois impede a delimitação da borda da lesão. Na Figura 5.16 temos um exemplo de uma imagem simulada, contendo sombreamento acústico, que foi submetida ao pré-processamento e segmentação pela rede SOM. É possível observar que em situações como essa, o contorno segue até a parte final da imagem, não conseguindo atingir o fechamento do objeto.

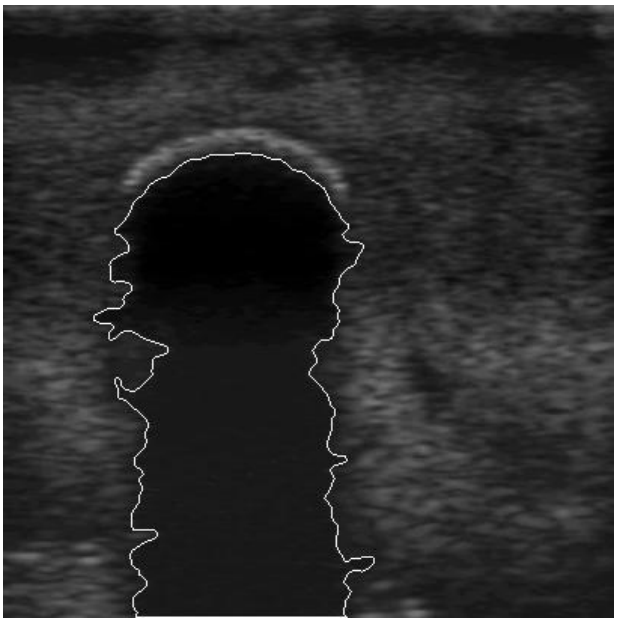

Figura 5.16 – Segmentação da imagem simulada com a presença de sombreamento acústico

Visualmente, podemos apontar a irregularidade nos limites da lesão, manifestando fortemente o seu caráter de malignidade, e isso é repassado para a classificação. Os descritores selecionados permitem que a rede neural MLP classifique esse tipo de achado como maligno, pois trata-se de um objeto com forma irregular, em decorrência de possíveis espículas em sua borda ou sombra, além do que, seu fechamento é dado por uma linha reta, diferentemente dos achados benignos, cujo contorno é definido e o formato é circular.

5.7 Software

O sistema final foi desenvolvido utilizando o *software MATLAB* versão 8.0 (R2012b) para ambientes com sistemas operacionais *Microsoft Windows 7* e *XP*. O *MATLAB*, por ser um ambiente de computação numérica baseado em matrizes, integra funções de tratamento numérico de alta performance e sofisticados recursos de geração de gráficos. Ele possui diversos módulos, chamados *toolboxes*, que contêm funções pré-determinadas, incluindo a de “Processamento de Imagens”, a qual compreende funções de filtragem, transformadas, detectores de borda, conversores, etc. Entretanto, seu maior problema é por ser um *software* proprietário, ou seja, é necessária a aquisição de uma licença para utilizá-lo. Para suprimir essa questão, foi produzido um arquivo executável contendo a versão final do sistema desenvolvido. Isso fez com que a instalação do *MATLAB* fosse dispensável, bem como a obtenção de uma licença para execução da aplicação.

O sistema produzido permite a realização da detecção e classificação de achados ultrassonográficos contidos na mama, com uma interface simples, ágil e de fácil manipulação pelo usuário.

O processo tem início com seleção da imagem de ultrassom, e segue com a realização do recorte de uma região suspeita. Esse recorte deve abranger a lesão e incluir a menor quantidade possível do tecido adjacente. Caso a ROI não tenha saído como o desejado, o usuário pode efetuar novo recorte.

Em seguida, é habilitado o processamento da imagem, segundo as técnicas previamente destacadas. Ao finalizar essa etapa, é possível visualizar a imagem resultante da sobreposição do contorno à ROI. O procedimento se encerra com a classificação, que avalia se a lesão pertence à classe benigna ou maligna. A

interface do sistema, assim como a execução de um exemplo são apresentadas na Figura 5.17.

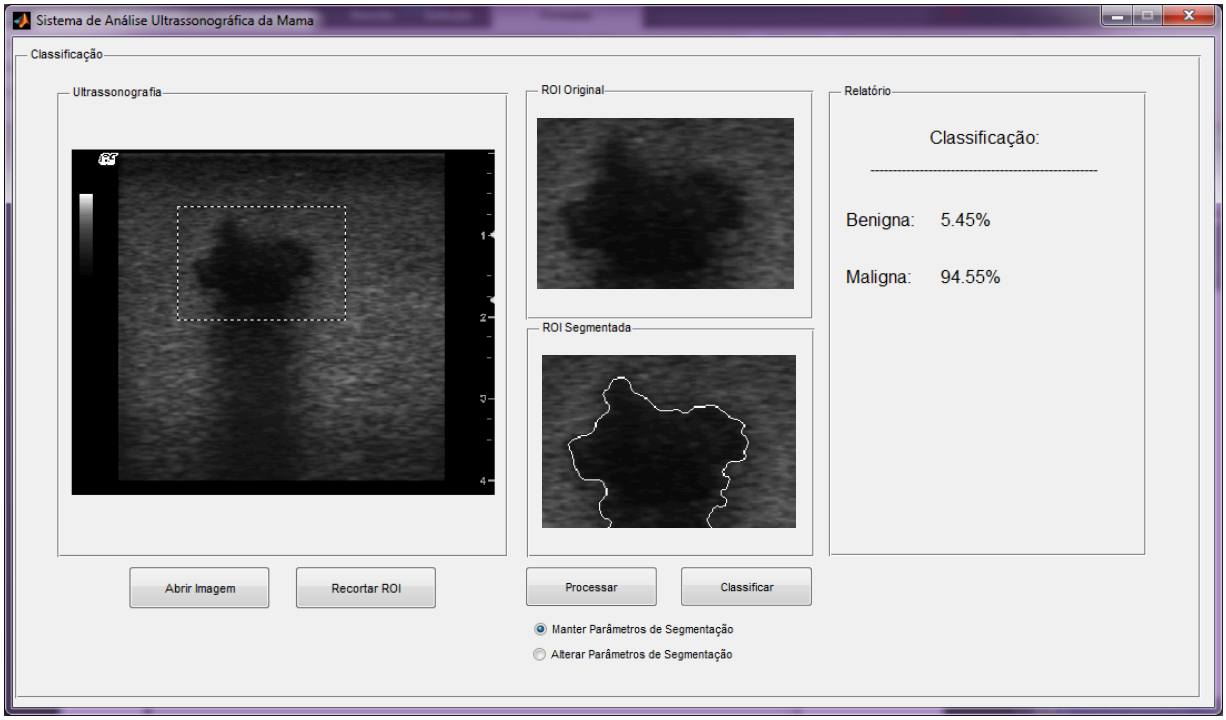

Figura 5.17 – Sistema de análise ultrassonográfica da mama

No caso de haver mais de uma lesão na mesma imagem, o usuário pode realizar um novo recorte compreendendo o outro achado suspeito. Em seguida, deve prosseguir com o processamento e a classificação.

Esse processo transcorre de forma totalmente automática. Entretanto, é notória a interferência que a segmentação exerce sobre a classificação. Dessa forma, o usuário pode alterar os parâmetros iniciais do segmentador, possibilitando uma delimitação mais adequada da lesão, com base na subjetividade visual do observador. Isso auxilia, consequentemente, a classificação de lesões delimitadas incorretamente.

Na Figura 5.18, por exemplo, ao manter inalterados os parâmetros iniciais de segmentação, temos uma lesão cujo delineamento não está adequado, havendo excessiva segmentação em sua parte inferior. Em virtude disso, a mesma é classificada erroneamente como maligna.

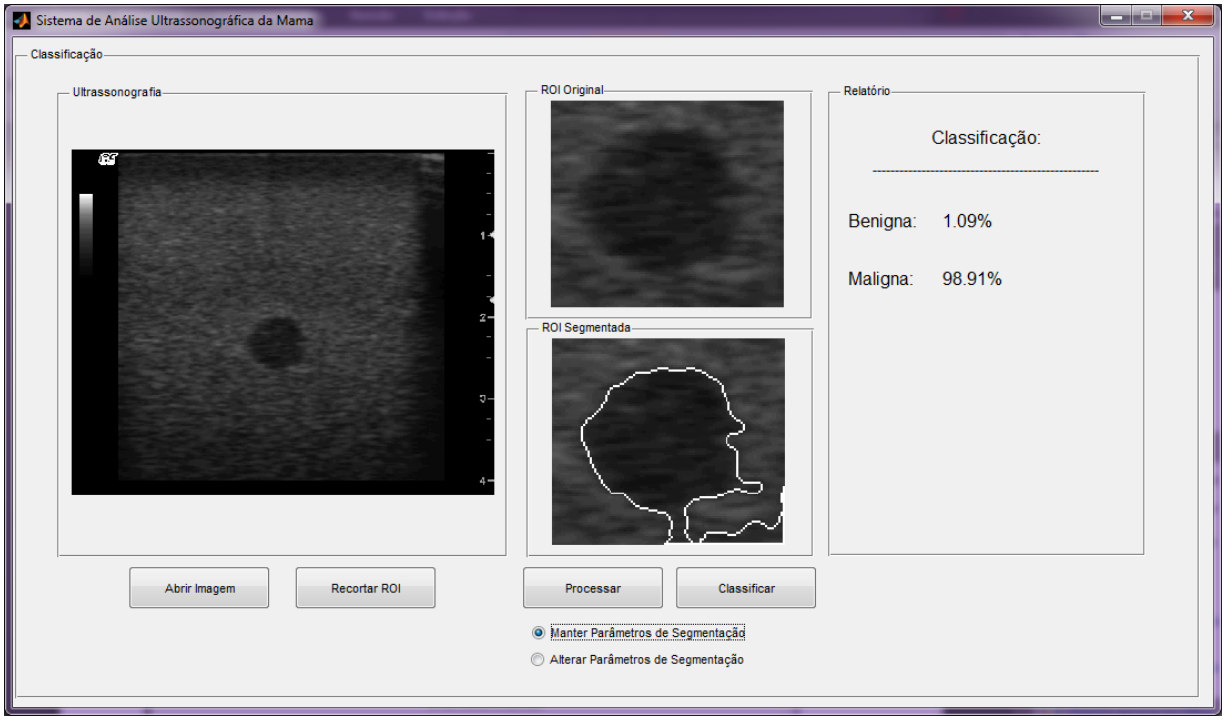

Figura 5.18 – Segmentação inadequada

Os parâmetros iniciais mencionados correspondem aos valores que definem o treinamento da rede SOM, compreendendo as variáveis de mínima e máxima intensidade de cinza, representada pelos valores zero e 255.

Caso seja selecionada a opção “Alterar Parâmetros de Segmentação”, será aberta uma janela que permite ao usuário modificar a máxima intensidade de cinza que, por definição, corresponde a 255, como exposto na Figura 5.19.

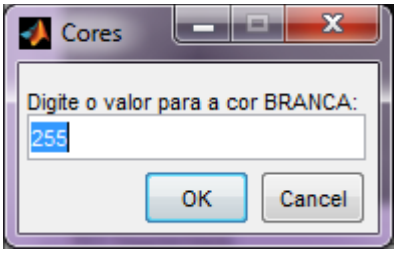

Figura 5.19 – Janela para alteração da intensidade máxima dos níveis de cinza

No caso de segmentação excessiva, esse valor deve decrescer. Com base nisso e seguindo com o exemplo da Figura 5.18, a mesma ROI é novamente processada, porém com a alteração do valor inicial para 200. O novo resultado é exibido na Figura 5.20. Como podemos notar, houve a mudança no contorno, cuja segmentação passou a definir melhor os limites da lesão e, consequentemente,

houve mudança na classificação, que passou a expor elevada tendência à benignidade.

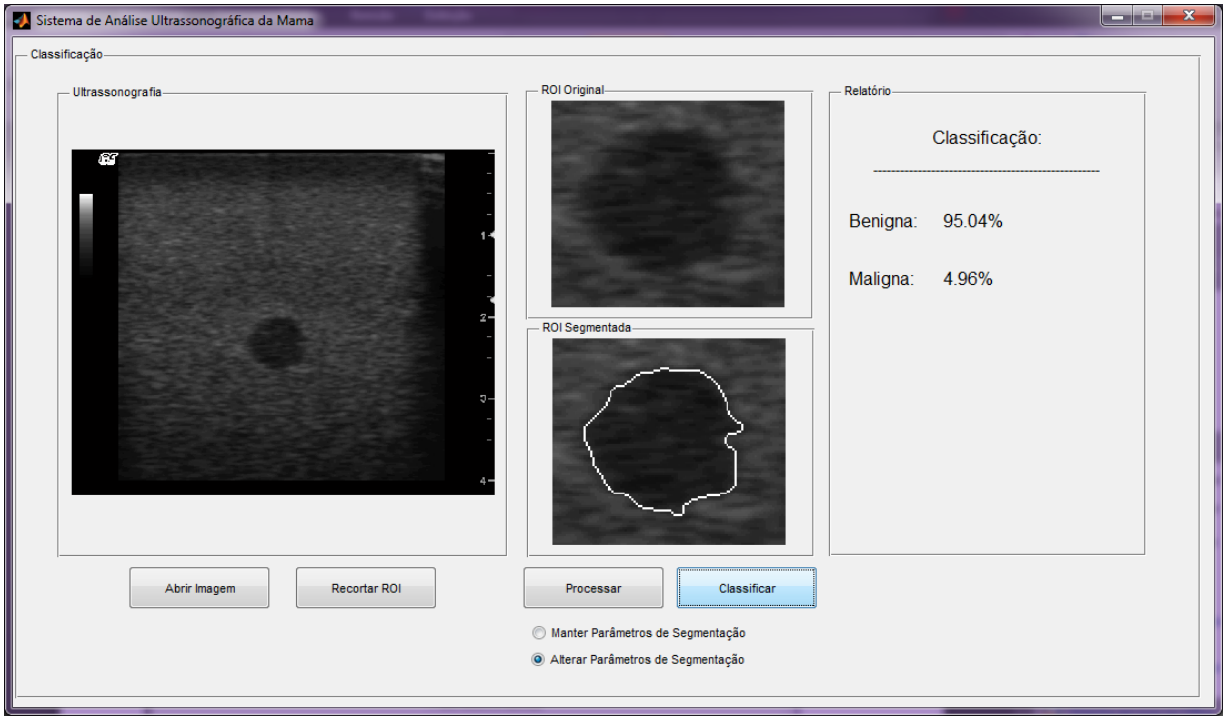

Figura 5.20 – Segmentação após a alteração dos parâmetros iniciais

É importante ressaltar que esse processo tem por base a análise visual para a determinação do valor mais adequado. Contudo, esse parâmetro só irá ser variado caso o usuário queira modificar a segmentação proporcionada automaticamente pelo sistema, entendendo que o objeto não esteja corretamente representado. Dessa forma, retrata apenas uma informação adicional ao *software* e não interfere em sua automatização, a menos que usuário deseje intervir.

6 CONCLUSÕES

A metodologia adotada nesse trabalho decorreu da procura de uma ferramenta que pudesse auxiliar no diagnóstico e tratamento precoce do câncer de mama para lesões encontradas em ultrassonografias.

As investigações promovidas buscam aprimorar o processamento digital em esquema CAD, permitindo a assistência na detecção e classificação de achados ultrassonográficos da mama. Os métodos oferecidos são de baixo custo computacional e oferecem respostas rápidas e precisas ao especialista, proporcionando a construção de uma ferramenta eficiente, ágil e de fácil usabilidade. Além disso, uma grande preocupação esteve voltada à automatização de todo o sistema, evitando a subjetividade visual e variação inter-observador.

6.1 Detecção das lesões

A principal razão de imprecisão em muitos esquemas CAD está relacionada a falhas durante a etapa de processamento digital da imagem. Isso ocorre em virtude da dificuldade na determinação precisa das fronteiras do objeto provocada, principalmente, pela interferência negativa exercida pelo ruído *speckle* (tipo

característico em ultrassom). Esse fenômeno agrava a qualidade da imagem e inibe a discriminação de alguns detalhes. Para minimizar esse problema, algumas técnicas de pré-processamento precederam a segmentação. O agravante na sua aplicação foi devido ao borramento das estruturas, afetando sobretudo as bordas da lesão. Contudo, a imagem de saída tornou-se mais uniforme, realçando o contraste entre o objeto de interesse e o fundo, o que auxiliou positivamente na detecção.

Mediante a ampla variedade de detectores, foram analisadas cinco técnicas de segmentação abordadas na literatura, sendo elas: crescimento de região, contorno ativo, *k*-means, fuzzy c-means e a rede neural SOM. A partir de resultados visualmente satisfatórios, tanto em imagens simuladas quanto em ultrassonografias clínicas, foram investigadas maneiras para quantificar a precisão com que cada algoritmo retratava o achado suspeito. Essa análise decorreu da comparação entre a representação fornecida manualmente por uma radiologista com as proporcionadas por cada detector. Com base nas dez medidas aplicadas para tal finalidade, sobressaíram as técnicas de segmentação por meio da rede neural SOM e por contorno ativo, em que foram apresentados índices mais elevados de precisão, ou seja, resultaram em um contorno mais próximo ao da radiologista. Consequentemente, obtiveram baixas taxas de erro, tanto na falta quanto no excesso de segmentação.

A grande vantagem do contorno ativo está na ausência de pré-processamento, pois não houve distorção nos limites da lesão, bem como em seu aspecto morfológico. Contudo, a imagem ficou mais suscetível ao ruído, passando a representar o objeto com bordas mais irregulares e espiculadas do que realmente eram. Esse fato pode apontar, erroneamente, a malignidade em alguns casos que, claramente, representam lesões benignas. Além disso, sua complexidade algorítmica requer muitas operações numéricas e interações até que seja promovida a conversão dos dados. Isso exige elevado custo computacional, resultando em um processo relativamente lento – atingindo cerca de 30 segundos para a execução em cada ROI.

Por produzir contornos mais suaves e respostas mais rápidas, a segmentação por meio da rede neural SOM foi determinada como a técnica de detecção mais precisa entre as testadas, além de permitir uma melhor compreensão das diferenças morfológicas entre lesões benignas e malignas.

Um fator que deve ser ressaltado é que as RNAs vêm sendo amplamente utilizadas para a resolução de problemas em imagens médicas por ser um procedimento baseado na simulação de vida, em especial no processo de aprendizagem do cérebro humano. Permitem melhorar os resultados a partir do desvio dos dados em uma situação normal, em que são oferecidos conjuntos iniciais de amostragem a fim de determinar as ligações e pesos entre os neurônios, e em seguida apresentar os dados para o treinamento neural. As ligações sinápticas entre os neurônios são, inicialmente, fornecidas aleatoriamente, e em seguida são ajustadas até que haja a convergência das informações. Essa aleatoriedade pode modificar o processo de conversão, refletindo em pequenas variações nos limites da lesão, ou seja, caso a mesma imagem seja novamente submetida ao processo de segmentação, é possível que ocorram modificações na borda do objeto. Esse processo assemelha-se à visualização por diferentes observadores, em que cada indivíduo vê elementos importantes de maneira distinta. Ainda sim, esse não é um fator prejudicial ao processo, pois não ocasiona grandes discrepâncias no resultado final.

6.2 Caracterização dos achados ultrassonográficos

A caracterização de um objeto por meio de técnicas computacionais parte, inicialmente, da obtenção de dados numéricos que representem suas características particulares. Esses valores foram obtidos a partir de descritores de forma e contorno descritos na literatura, analisando, assim, os aspectos morfológicos da lesão. Dos 25 descritores extraídos, nem todos auxiliaram positivamente na diferenciação dos achados e, como dificilmente se utiliza apenas uma medida para investigar a qual classe pertence o caso selecionado, faz-se necessária a combinação entre as características mais relevantes, ou seja, as que permitem descrever o objeto com precisão suficiente para sua identificação.

Nesse intuito, foram utilizadas duas ferramentas de seleção, que decorreu do uso do *AttributeSelection* e de curvas de distribuição Gaussiana. Ambos elegeram oito descritores como mais relevantes, porém divergiram em dois deles.

Para a caracterização dos achados ultrassonográficos, foi adotada a rede neural MLP, a qual passou por extensivos testes devido a modificações em sua

configuração topológica (alteração na quantidade de unidades sensoriais de entrada e quantidade de neurônios em sua única camada intermediária), bem como a modificação contínua na taxa de aprendizagem. Esse processo ocorreu para que fosse encontrada a configuração com melhor desempenho, em que foram determinados os seguintes descritores como entrada ao classificador: fator forma, razão de área e solidez. É possível notar concordância entre a metodologia de seleção de características adotada, pois as três foram denotadas como relevantes em ambos seletores.

A classificação em imagens simuladas alcançou o percentual de acerto de 94,2% na validação cruzada. Ao averiguar a generalização dos dados mediante a apresentação de imagens desconhecidas ao classificador, foi notório o alto desempenho obtido, em que o percentual de acerto alcançou 90%.

O treinamento em ultrassonografias clínicas não foi possível devido à baixa quantidade de imagens presentes no banco. Além disso, o número de casos que sugerem a malignidade da lesão era muito escasso. Sendo assim, a classificação dessas imagens foi realizada a partir do resultado obtido com treinamento em simuladores. O percentual de acerto nesse caso acabou ficando em 80,92%, porque muitas das lesões pertencentes a ultrassonografias clínicas se distanciavam um pouco, obviamente, dos padrões de treinamento promovido nas ROIs dos simuladores.

6.3 Considerações Finais

As imagens obtidas por simuladores contribuíram muito no desenvolvimento dessa pesquisa. Elas refletem um universo controlável, em que o material que constitui o objeto é conhecido, bem como suas características morfológicas, contribuindo significativamente para a generalização do classificador neural. Além disso, fornece maiores variações referentes à morfologia da lesão, sendo possível originar imagens de acordo com a necessidade do estudo. Permitiram ainda a ampliação do banco de imagens com igualdade entre a quantidade de lesões benignas e malignas.

O sistema final foi desenvolvido em ambiente *MATLAB* com a produção de um arquivo executável, o que dispensa a instalação do *software*. Além disso,

apresenta uma interface intuitiva e de fácil manipulação, fornecendo respostas rápidas e precisas ao especialista. A ferramenta foi totalmente automatizada, porém permite, se for o caso, a intervenção do usuário na melhoria do processo de segmentação por meio da alteração manual de alguns parâmetros. Considera-se, portanto, que o sistema produzido apresentou resultados satisfatórios, mesmo com a realização do treinamento neural apenas em imagens de *phantoms*, despontando como uma importante ferramenta de auxílio ao diagnóstico em ultrassonografias de mama.

6.4 Trabalhos Futuros

A continuidade deste trabalho pode ser aprofundada em pesquisas no âmbito de aprimorar o esquema de classificação desenvolvido. Para isto, apresentam-se algumas sugestões:

a) Aumentar o conjunto de imagens, principalmente envolvendo ultrassonografias clínicas. A partir dos novos dados, realizar o treinamento neural, garantindo maior confiabilidade na caracterização de imagens reais;
b) Melhorar a detecção do contorno da lesão;
c) Emprego de descritores de textura para determinação da ecogenicidade, sombra e reforço acústico posterior;
d) Investigação de outras ferramentas de classificação;
e) Confronto entre os exames de ultrassonografia, elastografia e mamografia no auxílio à detecção e diagnóstico precoce do câncer de mama.

REFERÊNCIAS BIBLIOGRÁFICAS

ALÉMAN-FLORES, M.; ALÉMAN-FLORES, P.; ÁLVAREZ-LEÓN, L.; ESTEBAN-SÁNCHEZ, M. B.; FUENTES-PAVÓN, R.; SANTANA-MONTESDEOCA, J. M. Semiautomatic snake-based segmentation of solid breast nodules on ultrasonography. In: *EUROCAST 2005: Lecture Notes in Computer Science (LNCS)*. Springer: Heidelberg, v. 6136, p. 39-45, 2010.

ALVARENGA, A. V.; PEREIRA, W. C. A.; INFANTOSI, A. F. C.; AZEVEDO, C. M. Classification of breast tumours on ultrasound images using morphometric parameters. *In: IEEE International Workshop on Intelligent Signal Processing*. Faro, Portugal, p. 206-210, set. 2005.

ALVES, P. Z. B. *Segmentação de imagens ultrassonográficas para detecção de nódulos*. 2010. 61 f. Dissertação de Mestrado, Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2010.

AZEVEDO, F. M.; BRASIL, L. M.; OLIVEIRA, R. C. L.; *Redes neurais*: com aplicações em controles e em sistemas especialistas. Florianópolis: Bookstore, 2000.

BANKMAN, I. N. (Ed.). *Handbook of medical image*: processing and analysis. 2 ed. London: Academic Press, 2009.

BOAVENTURA, I. A. G. *Números fuzzy em processamento de imagens digitais e suas aplicações na detecção de borda*. 2010. 109 f. Tese de Doutorado, Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2010.

BORGHESAN, D. H. P.; BARAÚNA, M.; PELLOSO, S. M.; CARVALHO, M. D. B. Auto-exame das mamas: conhecimento e prática entre profissionais da área da saúde de uma instituição pública. *Acta Scientiarum Health Sciences*. Maringá, v. 25, n. 1, p. 103-113, 2003.

BRAGA, Antônio de P.; CARVALHO, André C. P. de L. F.; LUDEMIR, Tereza B. *Redes neurais artificiais*: teoria e aplicações. Rio de Janeiro: LTC, 2007.

CALAS, M. J. G.; KOSH, H. A.; DUTRA, M. V. P. Ultra-sonografia mamária: avaliação dos critérios ecográficos na diferenciação das lesões mamárias. *Radiologia Brasileira*. São Paulo, v. 40, n. 1, p. 1-7, mar. 2007.

CARVALHO, Isabela M.; BASTO, Rodrigo L. Q.; INFANTOSI, Antonio F. C.; KRUGER, Marco A. V.; PEREIRA, Wagner C. A. Breast ultrasound phantom for image segmentation assessment. In: IEEE International Ultrasonics Symposium, 2009, Roma, Itália. *Proceedings of the IEEE - International Ultrasonics Symposium*, 2009. p. 2484-2487.

CHALA, L. F.; BARROS, N. Avaliação das mamas com métodos de imagem. *Radiologia Brasileira*. São Paulo, v. 40, n. 1, p. 4-6, fev. 2007.

CHANG, R.-F.; WU, W.-J.; MOON, W. K.; CHEN, D.-R. Automatic ultrasound segmentation and morphology based diagnosis of solid breast tumors. *Breast Cancer Research and Treatment*. v. 89, p. 179-185, jan. 2005.

CHIANG, H. K.; TIU, C.-M.; HUNG, G.-S.; WU, S.-C.; CHANG, T. Y.; CHOU, Y.-H. Stepwise logistic regression analysis of tumor contour features for breast ultrasound diagnosis. *In: IEEE Ultrasonics Symposium*. Atlanta, Georgia, v. 2, p. 1303-1306, out. 2001.

COSTA, F. M. L. *Ações de detecção precoce do câncer de mama realizadas por profissionais da estratégia da saúde*. 2009. 50 f. Dissertação de Mestrado, Universidade Federal do Rio Grande do Norte, Natal, 2009.

CVANCAROVA, M. ALBREGTSEN, F. BRABRAND, K. SAMSET, E. Segmentation of ultrasound images of liver tumors applying snake algorithms and GVF. In:

International Congress Series, 2005, Berlin. *Proceedings of 19th International Congress and Exhibition 2005*, v. 1281, p. 218-223, 2005.

DEMPSEY, P. J. The history of breast ultrasound. *Journal of Ultrasound in Medicine*, v. 23, p. 887-894, 2004.

DRUKKER, K.; PESCE, L. L.; GIGER, M. L. Repeatability and classifier bias in computer-aided diagnosis for breast ultrasound. *Medical Physics*, v. 37, n. 6, p. 2659-2669, 2010.

EVANS, A. L. *The evaluation of medical images*. Filadélfia: Heyden & Son, 1981.

FAWCETT, T. An introduction to ROC analysis. *Pattern Recognition Letters*, v. 27, n. 8, p. 861-874, 2006.

FOGAÇA, E. I. C.; GARROTE, L. F.; Câncer de mama: atenção primária e detecção precoce. *Arquivos de Ciência da Saúde*, São José do Rio Preto, v. 11, n. 3, p. 179-181, jul-set. 2004.

FORSYTH, D. A.; PONCE, J. *Computer vision*: A modern approach. New Jersey: Prentice Hall, 2003.

GÓMEZ, W.; LEIJA, L.; ALVARENGA, A. V.; INFANTOSI, A. F. C.; PEREIRA, W. C. A. Computerized lesion segmentation of breast ultrasound based on marker-controlled watershed transformation, *Medical Physics*, v. 37, n. 1, p. 82–95, 2010.

GONZALEZ, R. C; WOODS, R. E. *Processamento digital de imagens*. 3 ed. São Paulo: Prentice Hall, 2010.

HAYKIN, S. *Neural networks and learning machines*. 3 ed. New Jersey: Prentice Hall, 2008.

HUANG, Y.-L.; CHEN, D.-R.. Watershed segmentation for breast tumor in 2-D sonography. *Ultrasound in Medicine and Biology*, v. 30, n. 5, p. 625-632, maio 2004.

HUANG, Y.-L. Computer-aided Diagnosis Using Neural Networks and Support Vector Machines for Breast Ultrasonography. *Journal of Medical Ultrasound*, v. 17, p. 17-24, 2009.

JÄHANE, B. *Digital image processing*. 5 ed. Berlin: Springer, 2002.

JAN, J. *Medical image processing, reconstruction and restoration*: concepts and methods. New York: CRC Press, 2006.

JOO, S.; MOON W.K.; KIM, H.C. Computer-aided diagnosis of solid breast nodules on ultrasound with digital image processing and artificial neural network. *Proceedings of 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. San Francisco, Califórnia, USA. v. 1, p. 1397-1400, set. 2004

KEMP, C.; ELIAS, S.; BORELLI, K.; NARVAIZA, D. G.; KEMP, C. G. M.; SCHOR, A. P. Punção aspirativa por agulha fina orientada por ultra-sonografia em lesões não-palpáveis. *Revista Brasileira de Ginecologia e Obstetrícia*: Rio de Janeiro, v. 23, n. 5, p. 321-327, jun. 2001.

KOPANS, D. B. *Diagnóstico por imagem da mama*. 3 ed. Rio de Janeiro: Guanabara Koogan, 2008.

LOUVEIRA, M. H.; SOUZA, L. R. M. F.; CASTRO, I. M.; ELIAS, S.; SZEJNFELD, J.; KEMP, C. Avaliação e classificação ultra-sonográfica dos nódulos mamários: revisão da literatura e aspectos atuais. *Revista Imagem*, v. 23, n. 2, p. 123-128, 2003.

MARCOMINI, K. D.; SCHIABEL, H. Nodules Segmentation in Breast Ultrasound using the Artificial Neural Network Self-Organizing Map. In: World Congress on Engineering (2012 International Conference of Signal and Image Engineering), 2012, Londres, UK. *Proceedings of World Congress on Engineering 2012*, v. II. p. 1152-1155, jul. 2012a.

MARCOMINI, K. D.; SCHIABEL, H. Avaliação de técnicas de segmentação aplicadas em regiões suspeitas de imagens ultrassonográficas da mama. In: XXIII Congresso Brasileiro de Engenharia Biomédica, 2012, Porto de Galinhas, PE. *Anais do XXIII Congresso Brasileiro de Engenharia Biomédica*. p. 975-979, out. 2012b.

MARCOMINI, K. D.; SCHIABEL, H.; CARNEIRO, A. A. O. Quantitative evaluation of automatic methods for lesions detection in breast ultrasound images. Medical Imaging 2013: Computer-Aided Diagnosis, *Proceedings of SPIE 2013*, Orlando (FL), USA, fev. 2013. No prelo.

MARCOMINI, K. D.; SCHIABEL, H.; VERCOSA, L. B. Aplicação de contornos ativos para a segmentação de nódulos em imagens de ultrassonografia da mama. In: XVII

Congresso Brasileiro de Física Médica, 2012, Salvador, BA. *Anais do XVII Congresso Brasileiro de Física Médica*, 2012.

MARQUES FILHO, O.; VIEIRA NETO, H. *Processamento digital de imagens*. Rio de Janeiro: Brasport, 1999.

MARTINS, Letícia A. L.; BARRA, Alexandre A.; LUCENA, Clécio E. M. Microcalcificações mamárias suspeitas de malignidade. *Revista Brasileira de Cancerologia*, v. 56, n. 2, p. 251-258, 2010.

MASSICH, J.; MERIAUDEAU, F.; PÉREZ E.; MARTÍ, R.; OLIVER, A.; MARTÍ, J. Lesion segmentation in breast sonography. In: *Digital Mammography*: Lecture Notes in Computer Science (LNCS). Springer: Berlin, v. 6136, p. 39-45, 2010.

MÁTTAR, A. C.; MAUAD, F. M.; NASTRI, C. O. Atualizações em ultra-sonografia mamária. *Experts in Ultrasound: Reviews and Perspectives*, v. 1, n. 2, p. 82-86, 2009.

MEIRE, H. B.; FARRANT, P. *Basic Ultrasound*. New York : Wiley, 1995.

MENECHELLI, R. C.; RIBEIRO, P. B.; SCHIABEL, H. Desenvolvimento de um classificador da forma de nódulos mamográficos segmentados utilizando a rede neural artificial Multi-layer Perceptron (MLP). In: VI Workshop de Visão Computacional – WVC, 2010, Presidente Prudente/SP, *Anais do VI WVC'2010*, p. 180-185, jul. 2010.

MICHAILOVICH, O.; TANNENBAUM, A. Segmentation of medical ultrasound images using active contours. Image Processing, 2007, San Antonio, Texas, USA. *Proceedings of IEEE International Conference on Image Processing (ICIP)*, v. 6, p. 513-516, set. 2007.

MINGGIANG, Y.; KIDIYO, K.; JOSEPH, R. A survey of shape features extraction techniques. *Pattern Recognition*, p. 43-90, 2008.

NASCIMENTO, J. H. R. *Acurácia dos achados mamográficos e ultrassonográficos do câncer de mama: correlação da classificação BI-RADS e achados histológicos*. 2009. 43 f. Dissertação de Mestrado, Faculdade de Medicina, Pontifícia Universidade Católica do Rio Grande do Sul, Porto Alegre, 2009.

NASCIMENTO, J. H. R.; SILVA, V. D.; MACIEL, A. C. Acurácia dos achados ultrassonográficos do câncer de mama: correlação da classificação BI-RADS e achados histológicos. *Radiologia Brasileira*. v. 42, n.4, p. 235-240, ago. 2009.

NIXON, Mark; AGUADO, Alberto. *Feature extraction and image processing*. 2 ed. San Diego: Academic Press, 2008.

PATROCINIO, A. C. *Classificador automático de achados mamográficos em imagens digitais de mamas densas utilizando técnicas híbridas*. 2004. 94 f. Tese de Doutorado, Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2004.

PATROCINIO, A. C.; ANGELO, M. F.; SCHIABEL, H. Análise estatística de atributos extraídos de lesões mamárias. In: XXII Congresso Brasileiro de Engenharia Biomédica, 2010, Tiradentes/MG. Anais do XXII CBEB'2010, p. 886-890, 2010.

PATROCINIO, A. C.; SCHIABEL, H.; SANTAELLA, C. H. M.; ROMERO, R. A. F. Análise de atributos extraídos de nódulos mamográficos para identificação de formatos. In: XVIII Congresso Brasileiro de Engenharia Biomédica - CBEB, 2002, São José dos Campos-SP. Anais do CBEB'2002, v.1, p. 317-320, 2002.

PAULINELLI, R. R.; CALAS, M. J. G.; FREITAS JÚNIOR, R. BIRADS e ultra-sonografia mamária: uma análise crítica. *Federação Brasileira das Sociedades de Ginecologia e Obstetrícia*, v. 35, n. 9, p. 565-572, set. 2007.

PAULINELLI, R. R.; MOREIRA, M. A. R.; FREITAS JUNIOR, R. Ultra-sonografia no diagnóstico do câncer de mama: realidade atual e possibilidades para o futuro. *Revista Brasileira de Mastologia*. v. 13, n. 4, p. 168-174, 2003.

PEI, C.; WANG, C.; XU, S. Segmentation of the breast region in mammograms using marker-controlled watershed transform. In: 2nd International Conference on Information Science and Engineering, Hangzhou, China, *Proceedings of ICISE'2010*, p. 2371-2374, dez. 2010.

PEURA, M.; IIVARINEN, J. Efficiency of simple shape descriptors. In: 3rd International Workshop on Visual Form, Capri, Itália, Proceedings of IWVC3, p. 443–451, maio 1997.

PRATT, W. K. *Digital image processing*: piks scientific inside. 4 ed. New Jersey: Wiley, 2007.

RUSS, J. *The Image Processing Handbook*. 2 ed. Boca Raton: CRC Press, 1995.

SANDHU, R.; GEORGIOU, T.; TANNENBAUM, A. A new distribution metric for image segmentation. Medical Imaging 2008: Image Processing, *Proceedings of SPIE 2008*, Marseille, França, v. 6914, p. 691404-1–691404-9, fev. 2008.

SANTIN, J. L. Ultra-som: técnica e aplicação. 2 ed. Curitiba: Artes gráficas e Editora Unificado, 2003.

SANTOS, V. Segmentação de imagens mamográficas para a detecção de nódulos em mamas densas. 2002. 56 f. Dissertação de Mestrado, Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2002.

SHAN, J.; CHENG, H.-D.; Wang, Y. A completely automatic segmentation method for breast ultrasound images using region growing. *Proceedings of the 9th International Conference on Computer Vision, Pattern Recognition, and Image Processing*, 2008.

SHI, X.; CHENG, H. D.; HU, L.; JU, W.; TIAN, J.; Detection and classification of masses in breast ultrasound images. *Digital Signal Processing*, v. 20, n. 3, p. 824-836, 2010.

SILVA, A. O. *Transformada de watershed para a segmentação de imagens médicas da região pélvica*. 2003. 65 f. Dissertação de Mestrado, Faculdade de Tecnologia, Universidade de Brasília, Brasília, 2003.

SILVA, C. Y. V. W. *Extração de características de imagens médicas utilizando wavelets para mineração de imagens e auxílio ao diagnóstico*. 2007. 53 f. Dissertação de Mestrado, Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2007.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. *Redes neurais artificiais para a engenharia e ciências aplicadas*. São Paulo: ArtLiber, 2010.

SILVA, M. P. S. Mineração de Dados – Conceitos, Experimentos e Aplicações com WEKA, *In: Escola Regional de Informática RJ/ES*, Sociedade Brasileira de Computação, v.1, p. 19-21, 2004.

SONKA, M.; FITZPATRICK, M. *Handbook of medical imaging processing and analysis*. v. 2, Bellingham: SPIE Press, 2000.

SOUZA, T.; CORREIA, S. Estudo de Técnicas de Realce de Imagens Digitais e suas aplicações. In: II Congresso de Pesquisa e Inovação da Rede Norte Nordeste de Educação Tecnológica – II CONNEPI, 2007, João Pessoa/PB. *Anais do CEFET-PB'2007*. v. 2, p. 3-10, 2007.

STAVROS, A. T.; New advances in breast ultrasound: computer-aided detection. *Ultrasound Clinics*, v. 4, n. 3, p. 285-290, jul. 2009.

TAKAHASHI, A.; BEDREGAL, B. R. C.; LYRA, A. Uma versão intervalar do método de segmentação de imagens utilizando o k-means. *Tendências em Matemática Aplicada e Computacional (TEMA)*, v. 6, n. 2, p.315-324, 2005.

TENG, W.-G.; CHANG, P.-L. Identifying regions of interest in medical images using self-organizing maps. *Journal of Medical Systems*, jul. 2011.

VIEIRA, S. L. *Desenvolvimento de um "phantom" para treinamento de biópsia de mama guiada por ultra-som*. 2005. 46 f. Dissertação de Mestrado, Faculdade de Filosofia Ciências e Letras de Ribeirão Preto, Universidade de São Paulo, Ribeirão Preto, 2005.

WEBB, Andrew. *Introduction to biomedical imaging*. Wiley: New Jersey, 2003.

WIRTH, M.; NIKITENKO, D.; LYON, J. Segmentation of the breast region in mammograms using a rule-based fuzzy reasoning algorithm. *ICGST-GVIP Journal*, v. 5, n. 2, p. 45-54, jan. 2005.

WITTEN, I. H.; FRANK, E. *Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations*. WEKA - Machine Learning Algorithms in Java. Morgan Kaufmann Publishers, 2010.

WORLD HEALTH ORGANIZATION (WHO). *Manual of diagnostic ultrasound*. Malta: Gutenberg Press, 2011.

XU, Y. Image decomposition based ultrasound image segmentation by using fuzzy clustering. *IEEE Symposium on Industrial Electronics and Applications – ISIEA*, v. 1, p. 6-10, out. 2009.

YAP, M. H.; EDIRISINGHE, E. A.; BEZ, H. E. Object boundary detection in ultrasound images. IEEE 3rd Canadian Conference on Computer and Robot Vision 2006, 2006. Quebec, Canadá. *Proceedings of CRV'06*, p. 53-58, jun. 2006.

YAP, M. H.; EDIRISINGHE, E. A.; BEZ, H. E. A comparative study in ultrasound breast imaging classification. Medical Imaging 2009: Image Processing, *Proceedings of SPIE 2009*, San Diego, Califórnia, v. 7259, p. 72591S-1 – 72591S-11, ago. 2009.

YU, D.; LEE, S.; LEE, J. W.; SEUNGHWAN, K. Automatic lesion detection and segmentation algorithm on 2D breast ultrasound images. Medical Imaging 2011: Computer-Aided Diagnosis, *Proceedings of SPIE 2011*, Orlando, Flórida, v. 7963, p.79631Y-1–79631Y-6, fev. 2011.

ZHANG, D.; LU, G. Review of shape representation and description techniques. *Pattern Recognition*, v. 37, p. 1-19, 2004.

ZHU, C.; NI, J.; LI, Y. Speckle noise suppression techniques for ultrasound images. In: IEEE Fourth International Conference on Internet Computing for Science and Engineering, Harbin, China. *Proceedings of ICICSE'2009*, p. 122-125, dez. 2009a.

ZHU C.; NI, J.; LI, Y; GU, G. General Tendencies in Segmentation of Medical Ultrasound Images. In: IEEE Fourth International Conference on Internet Computing for Science and Engineering, Harbin, China, *Proceedings of ICICSE'2009*, p. 113-117, dez. 2009b.