



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA ELÉTRICA
PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA

PEDRO CUNHA CARNEIRO

CLASSIFICAÇÃO MAMOGRÁFICA POR DENSIDADE
MAMÁRIA UTILIZANDO ATRIBUTOS DE
INTENSIDADE E TEXTURA

Uberlândia

2015

PEDRO CUNHA CARNEIRO¹

CLASSIFICAÇÃO MAMOGRÁFICA POR DENSIDADE MAMÁRIA UTILIZANDO
ATRIBUTOS DE INTENSIDADE E TEXTURA

Dissertação de mestrado submetida ao Programa
de Pós-Graduação em Engenharia Biomédica da
Universidade Federal de Uberlândia, como
requisito parcial à obtenção do título de Mestre
em Ciências.

Área de concentração: Engenharia Biomédica
Orientador: Prof^a. Dr^a. Ana Claudia Patrocínio
Co-orientador: Prof. Dr. Diego Merigue da Cunha

Uberlândia

2015

¹ A Bolsa de Estudos, para esta pesquisa, foi concedida pela CAPES, Brasil.

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

C289c
2015

Carneiro, Pedro Cunha.

Classificação mamográfica por densidade mamária utilizando atributos de intensidade e textura / Pedro Cunha Carneiro. - 2015.

112 f. : il.

Orientadora: Ana Claudia Patrocínio.

Coorientador: Diego Merigue da Cunha.

Dissertação (mestrado) - Universidade Federal de Uberlândia, Programa de Pós-Graduação em Engenharia Biomédica.

Inclui bibliografia.

1. Engenharia biomédica - Teses. 2. Mamas - Câncer - Teses. 3. Redes neurais (Computação) - Teses. I. Patrocínio, Ana Claudia. II. Cunha, Diego Merigue da. III. Universidade Federal de Uberlândia, Programa de Pós-Graduação em Engenharia Biomédica. IV. Título.

CDU: 62:61

PEDRO CUNHA CARNEIRO

CLASSIFICAÇÃO MAMOGRÁFICA POR DENSIDADE MAMÁRIA UTILIZANDO
ATRIBUTOS DE INTENSIDADE E TEXTURA

Dissertação de mestrado submetida ao Programa de Pós-Graduação em Engenharia Biomédica da Universidade Federal de Uberlândia, como requisito parcial à obtenção do título de Mestre em Ciências.

Área de concentração: Engenharia Biomédica

Uberlândia, 27 de Agosto de 2015.

Banca Examinadora:

Ana Claudia Patrocínio, Dr^a. – FEELT / UFU (Orientador)

Diego Merigue da Cunha, Dr. – INFIS / UFU

Michele Fúlvia Angelo, Dr^a. – DTEC / UEFS

Prof^a. Ana Claudia Patrocínio, Dr^a.
Orientador

Prof. Edgard Afonso Lamounier Júnior, Dr.
Coordenador da Pós-Graduação

Dedico esse trabalho à minha família,
sobretudo à meu avô Geraldo Carneiro, o homem
mais sábio que já conheci.

AGRADECIMENTOS

À minha orientadora, professora Ana Cláudia Patrocínio, primeiramente pela orientação durante o trabalho, mas principalmente pelo conhecimento, paciência, disposição e amizade durante todo esse tempo de convivência.

Ao meu pai, por ser meu ídolo, meu maior motivador, meu melhor amigo e grande responsável por essa conquista.

À minha mãe, por acordar sempre de bom humor fazendo com que meu dia começasse melhor, pelas risadas diárias e por cuidar tão bem de mim.

À minha irmã, por ser uma grande inspiração pra mim. Apesar da convivência mais virtual que real, a sua dedicação e responsabilidade na vida acadêmica me motivaram para a conclusão deste trabalho.

À meus avós, tios e primos, por estar sempre presente ao meu lado, me apoiando e me aguentando em todas as crises de mau humor durante a semana.

À minha namorada, por estar sempre ao meu lado em todos os momentos, me confortando quando eu mais precisava e me animando nos momentos mais difíceis.

Por todo o (des)apoio de meus amigos do time de futebol Resenha Braba F.C., que conviveram comigo neste importante período e entenderam a minha ausência em algumas “resenhas”.

Aos meus amigos de infância, por todos (os poucos) encontros e toda conversa jogada fora durante alguns finais de semana.

Aos meus colegas de laboratório do Biolab (“Aquário”) pelas risadas e ajudas inusitadas durante a execução do trabalho.

Ao grupo de pesquisa “Ciências” por todas as dúvidas, ideias e sugestões propostas durante as reuniões semanais.

Ao *Breast Research Group* de Porto, Portugal pelo fornecimento das imagens mamográficas utilizadas neste trabalho.

E a todos que contribuíram de alguma forma para a execução deste trabalho.

“A vida é como andar de bicicleta. Para manter o equilíbrio é necessário estar sempre em movimento.” (Albert Einstein)

SUMÁRIO

| | |
|--|-----|
| RESUMO | iii |
| ABSTRACT | iv |
| LISTA DE FIGURAS | v |
| LISTA DE TABELAS | vii |
| LISTA DE ABREVIATURAS E SIGLAS | x |
| Capítulo 1 INTRODUÇÃO GERAL..... | 16 |
| 1.1 Objetivo..... | 17 |
| 1.2 Objetivos Específicos | 17 |
| 1.3 Justificativa..... | 18 |
| 1.4 Estrutura da Dissertação..... | 19 |
| Capítulo 2 MAMOGRAFIA E DENSIDADE MAMÁRIA | 20 |
| 2.1 Conceitos gerais de mamografia | 20 |
| 2.2 Mamografia convencional..... | 23 |
| 2.3 Mamografia digital..... | 24 |
| 2.4 Densidade mamária e padronização da classificação..... | 26 |
| Capítulo 3 ESTADO DA ARTE | 30 |
| 3.1 Classificação de imagens por densidade mamária | 30 |
| Capítulo 4 ANÁLISE E CLASSIFICAÇÃO DE IMAGENS | 45 |
| 4.1 Extração de atributos | 45 |
| 4.1.1 Atributos extraídos do histograma | 46 |
| 4.1.2 Atributos de textura | 47 |
| 4.2 Seleção de atributos | 50 |
| 4.3 Classificação de imagens..... | 52 |
| 4.3.1 Técnica de agrupamento <i>k-means</i> | 53 |
| 4.3.2 Redes Neurais Artificiais..... | 54 |
| 4.3.3 Algoritmo <i>Backpropagation</i> | 57 |
| Capítulo 5 METODOLOGIA | 61 |

| | |
|--|-----------|
| 5.1 Banco de imagens | 63 |
| 5.1.1 <i>Banco de imagens Mini-MIAS</i> | 63 |
| 5.1.2 <i>Banco de imagens INbreast</i> | 64 |
| 5.2 Extração de atributos | 66 |
| 5.2.1 <i>Pré-processamento das imagens</i> | 66 |
| 5.2.2 <i>Extração de atributos de intensidade (histograma) e descritores de textura de Haralick</i> .. | 68 |
| 5.3 Seleção de atributos | 69 |
| 5.3.1 <i>Distribuição normal (Gaussiana)</i> | 70 |
| 5.3.2 <i>K-means para seleção de atributos</i> | 72 |
| 5.4 Classificação das imagens | 72 |
| 5.4.1 <i>K-means como classificador</i> | 72 |
| 5.4.2 <i>Redes Neurais Artificiais</i> | 73 |
| Capítulo 6 ANÁLISE DE ATRIBUTOS..... | 78 |
| 6.1 Análise de atributos das imagens em filme | 78 |
| 6.2 Resultados da seleção dos atributos das imagens em filme | 83 |
| 6.3 Análise dos atributos das imagens digitais | 83 |
| 6.4 Resultado da seleção dos atributos das imagens digitais | 88 |
| Capítulo 7 RESULTADOS E DISCUSSÕES | 91 |
| 7.1 Classificação das imagens em filme | 91 |
| 7.2 Classificação das imagens digitais..... | 93 |
| Capítulo 8 CONCLUSÕES | 101 |
| REFERÊNCIAS | 103 |

RESUMO

CARNEIRO, P. C. **Classificação mamográfica por densidade mamária utilizando atributos de intensidade e textura.** Dissertação de mestrado – Faculdade de Engenharia Elétrica, Engenharia Biomédica, Universidade Federal de Uberlândia, 2015.

O câncer de mama é um problema global, sendo o tipo de câncer mais frequente na mulher brasileira. O tipo de tecido predominante da mama, isto é, a densidade mamária, está fortemente associada ao risco de se contrair câncer de mama, visto que mamas densas podem dificultar a visualização de alguns tumores. A melhor forma de se prevenir tal enfermidade é a partir do exame de mamografia, apresentando este, alto grau de subjetividade e dependente principalmente da experiência do profissional que analisa a imagem. Sistemas de auxílio ao diagnóstico vêm sendo utilizados frequentemente por médicos radiologistas como ferramenta na detecção precoce do câncer de mama. A abordagem deste trabalho é de que mamogramas de diferentes padrões de densidade mamária são representados por tecidos diferentes, e consequentemente com diferentes características, podendo então ser diferenciados por seus atributos. Dessa forma, o objetivo deste trabalho é propor um método de classificação de imagens mamográficas em padrões de densidade mamária a partir da extração de atributos do histograma e de textura. Os primeiros testes foram feitos em imagens mamográficas em filme, e posteriormente foi utilizado um banco de imagens digitais a fim de verificar a influência dos atributos em diferentes imagens. No primeiro teste, com 75 mamogramas em filme, foi usada a técnica de agrupamento *k-means* que obteve 96% de acerto na classificação. Já para as 307 imagens digitais testadas, foi proposta a utilização de redes neurais artificiais, que conseguiu classificar corretamente 99,26% dos mamogramas em quatro classes de padrão de densidade mamária.

Palavras-Chave: Câncer de mama. Classificação. Densidade mamária. Extração de atributos. Redes neurais artificiais.

ABSTRACT

CARNEIRO, P. C. **Breast density classification through intensity and texture features.** Dissertação de mestrado – Faculdade de Engenharia Elétrica, Engenharia Biomédica, Universidade Federal de Uberlândia, 2015.

Breast cancer is a global problem, being the most frequent kind of cancer among Brazilian women. The most common tissue on the breast, that is, the breast density, is strongly associated with the risk of developing breast cancer, once dense breasts may hinder the visualization of some tumors. The best way to prevent such illness is through the mammography exam, which has a certain degree of subjectivity and depends mainly on the professional experience of the one who analyses the images. Computer-aided systems have frequently been used by radiology doctors as a tool to detect breast cancer at an early stage. The approach of this paper is that different mammography exams that show different breast density are represented by different tissues and, thus, are of different characteristics, which can be differed by their features. This way, the aim of this paper is to propose a method of classification of mammography images in density patterns from the extraction of features from the histogram and texture. The first tests were done in screen-film mammography images, and later, a digital database was used in order to verify the influence of features in different images. On the first test, with 75 screen-film mammography images, the *k-means* clustering technique was used and the classification was 96% accurate. When the 307 images were tested, the use of artificial neural networks was proposed and the classification of 99,26% mammography images was accurate in four classes of the pattern of breast density.

Keywords: Breast Cancer. Classification. Breast density. Features extraction. Artificial neural network.

LISTA DE FIGURAS

| | |
|--|----|
| Figura 2.1 – Sistema mamográfico. | 20 |
| Figura 2.2 – Posições de exposição para exames mamográficos. (a) Incidência MLO. | |
| (b) Incidência CC..... | 22 |
| Figura 2.3 – Exemplo de uma imagem de mamografia convencional sob vista médio-lateral. | 23 |
| Figura 2.4 - Exemplo de uma imagem de mamografia digital sob vista médio-lateral. 25 | |
| Figura 3.1 – Comparação entre as regiões de tecido fibroglandular encontradas pelos residentes (traçado mais grosso) e pelo método automático (traçado mais fino). (a) Mama gordurosa. (b) Mama gordurosa-glandular. (c) Mama glandular. (d) Mama glandular com baixo índice de acerto. | 31 |
| Figura 3.2 – (a) Exemplo de mamogramas usado no trabalho. (b) Mama com o limite e o músculo peitoral detectador. (c) Mapa binário da imagem segmentada apenas com região mamária. | 32 |
| Figura 3.3 – (a) Mama predominantemente adiposa. (b) Mama com pouco tecido fibroglandular. (c) Mama heterogeneamente densa. (d) Mama extremamente densa..... | 33 |
| Figura 3.4 – Mamas densas e a borda interna encontrada pelo algoritmo do software .36 | |
| Figura 3.5 – Segmentação da mama: (a) Imagem original. (b) Segmentação do fundo. | |
| (c) Diferenciação do ruído com a área útil da mama. (d) Imagem binária sem artefatos. (e) Imagem sem artefatos..... | 37 |
| Figura 3.6 – Imagens sob vista MLO da categoria II do BI-RADS TM : (a) Imagem <i>raw</i> . | |
| (b) Imagem processada..... | 41 |
| Figura 4.1 – Distribuição normal (Gaussiana). | 51 |
| Figura 4.2 – Modelo simples de uma Rede Neural Artificial. | 55 |

| | |
|---|----|
| Figura 4.3 – Esquema simples de uma rede <i>feedforward</i> com algoritmo <i>backpropagation</i> | 58 |
| Figura 5.1 – Diagrama resumo da etapa de processamento das imagens..... | 62 |
| Figura 5.2 – Banco mini-MIAS: exemplo de imagens pré-processadas das três classes de densidade mamária. (a) Classe gordurosa. (b) Classe gordurosa-glandular. (c) Classe densa. | 64 |
| Figura 5.3 – INbreast: imagens sob vista MLO. (a) Padrão 1: gorduroso. (b) Padrão 2: . (c) Padrão 3. (d) Padrão 4: denso | 65 |
| Figura 5.4 – INbreast: imagens sob vista CC. (a) Padrão 1: gorduroso. (b) Padrão 2: 26-50% de tecido fibroglandular. (c) Padrão 3: 51% a 75% de tecido fibroglandular. (d) Padrão 4: denso..... | 66 |
| Figura 5.5 – Segmentação das imagens: (a) Imagem original. (b) Imagem segmentada: retirada do músculo peitoral e de informações em texto..... | 67 |
| Figura 5.6 – Banco mini-MIAS: exemplo de imagens pré-processadas das três classes de densidade mamária. (a) Classe gordurosa. (b) Classe gordurosa-glandular. (c) Classe densa. | 67 |
| Figura 5.7 – Curvas gaussianas com boa separabilidade entre as classes. (a) Média de níveis de cinza do histograma. (b) Maior pico do histograma. (c) Uniformidade. (d) Correlação..... | 70 |
| Figura 5.8 – Curvas gaussianas com separabilidade ruim entre as classes. (a) Menor intensidade de pixel do histograma. (b) Gradiente. (c) Variância. (d) Entropia da diferença.. | 71 |
| Figura 5.9 – Gráfico das funções de ativação testadas: (a) Linear. (b) <i>Logsig</i> , (c) <i>Tansig</i> | 75 |
| Figura 5.10 – RNA: diagrama com a divisão do conjunto de imagens em grupo treino e teste..... | 76 |

LISTA DE TABELAS

| | |
|---|----|
| Tabela 3.1 – Distribuição da quantidade de imagens <i>raw</i> e processadas utilizadas a partir das categorias BI-RADS™..... | 39 |
| Tabela 3.2 – Comparação de métodos de classificação de densidade mamária encontrados na literatura (k-NN: vizinhos mais próximos, RBH: <i>rule-based histogram</i> , RNA: Rede Neural Artificial, ID3: árvore de decisão, SVM: máquina de vetor de suporte, LBN: <i>linear Bayes normal</i> , VT: <i>voting tree</i>)..... | |
| | 44 |
| Tabela 5.1 – INbreast: distribuição da quantidade de imagens pertencentes a cada padrão de densidade mamária..... | 65 |
| Tabela 5.2 – Grupo Treino x Grupo Teste: Número de imagens referentes a cada padrão de densidade mamária..... | |
| | 75 |
| Tabela 5.3 – Resumo geral de todo o estágio de processamento das imagens..... | 77 |
| Tabela 6.1 – Média aritmética e média dos desvios padrão dos atributos extraídos do histograma para imagens em filme..... | |
| | 78 |
| Tabela 6.2 – Coeficiente de variação (porcentagem) dos atributos extraídos do histograma para as imagens em filme..... | 80 |
| Tabela 6.3 – Média aritmética e média dos desvios padrão dos atributos de textura de Haralick para as imagens em filme..... | |
| | 81 |
| Tabela 6.4 – Coeficiente de variação (porcentagem) dos atributos de textura para as imagens em filme..... | 82 |
| Tabela 6.5 – Média aritmética e média dos desvios padrão dos atributos extraídos do histograma para imagens digitais..... | |
| | 84 |

| | |
|--|----|
| Tabela 6.6 – Coeficiente de variação (porcentagem) dos atributos extraídos do histograma para as imagens digitais..... | 85 |
| Tabela 6.7 – Média aritmética e média dos desvios padrão dos atributos de textura de Haralick para as imagens digitais..... | 86 |
| Tabela 6.8 – Coeficiente de variação (porcentagem) dos atributos de textura para as imagens digitais. | 87 |
| Tabela 6.9 – Porcentagem de acerto invididual dos atributos extraídos do histograma e da combinação de todos eles | 88 |
| Tabela 6.10 – Porcentagem de acerto individual dos atributos de textura de Haralick e da combinação de todos eles. | 89 |
| Tabela 6.11 – Porcentagem de acerto da combinação de alguns atributos..... | 90 |
| Tabela 6.12 – Grupo de atributos selecionados para serem usados como entrada para a Rede Neural Artificial..... | 90 |
| Tabela 7.1 – Atributos extraídos do histograma: porcentagem de acerto e número de erros a partir da técnica de classificação <i>k-means</i> | 91 |
| Tabela 7.2 – Atributos de textura: porcentagem de acerto e número de erros a partir da técnica de classificação <i>k-means</i> | 92 |
| Tabela 7.3 – RNA 1: parâmetros utilizados e o melhor resultado (porcentagem de acerto) obtido para essa configuração..... | 94 |
| Tabela 7.4 – RNA 1: número de inversões da classificação das imagens em padrões de densidade cometidas pela configuração de melhor resultado da rede. | 94 |
| Tabela 7.5 – RNA 2: parâmetros utilizados e o melhor resultado (porcentagem de acerto) obtido para essa configuração..... | 95 |

| | |
|---|----|
| Tabela 7.6 – RNA 2: número de inversões da classificação das imagens em padrões de densidade cometidas pela configuração de melhor resultado da rede..... | 96 |
| Tabela 7.7 – RNA 3: parâmetros utilizados e o melhor resultado (porcentagem de acerto) obtido para essa configuração..... | 96 |
| Tabela 7.8 – RNA 3: número de inversões da classificação das imagens em padrões de densidade cometidas pela configuração de melhor resultado da rede..... | 97 |
| Tabela 7.9 – RNA 4: parâmetros utilizados e o melhor resultado (porcentagem de acerto) obtido para essa configuração..... | 97 |
| Tabela 7.10 – RNA 5: parâmetros utilizados e o melhor resultado (porcentagem de acerto) obtido para essa configuração..... | 98 |
| Tabela 7.11 – Resumo dos resultados. | 99 |
| Tabela 7.12 – Média de erros por padrão durante os dez treinamentos com a melhor configuração de cada uma das cinco redes testadas. | 99 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|----------|--|
| A/D | Analógico/Digital |
| ACR | <i>American College of Radiology</i> (Colégio Americano de Radiologia) |
| AEC | <i>Automatic exposure control</i> (Controle automático de exposição) |
| ART | <i>Adaptative Ressonance Theory</i> |
| BI-RADS™ | <i>Breast Imaging Reporting and Data System</i> |
| BP | <i>Backpropagation</i> (Retropropagação) |
| CAD | <i>Computer-aided diagnosis</i> (Diagnóstico auxiliado por computador) |
| CC | Crânio-caudal |
| CR | <i>Computed Radiography</i> (Radiografia computadorizada) |
| CV | Coeficiente de variação de Pearson |
| DDDS | <i>Digital Database of Screening Mammographies</i> |
| DICOM | <i>Digital Imaging and Communications in Medicine</i> |
| DN | <i>Digital Numbers</i> |
| EQM | Erro quadrático médio |
| FCM | <i>Fuzzy c-means</i> |
| FFDM | <i>Full Field Digital Mammography</i> |
| IP | <i>Image plate</i> |
| kEv | Quilo elétron-volt |
| k-NN | <i>k-Nearest Neighbors</i> (k-vizinhos mais próximos) |
| LBN | <i>Linear Bayes normal</i> |
| mAs | Milimpère por segundo |
| MATLAB | <i>MATrix LABoratory</i> |
| MLO | Médio lateral oblíqua |
| PCA | <i>Principal Component Analysis</i> |
| PD% | <i>Percent density</i> (Porcentagem de densidade mamária) |
| RBH | <i>Rule-based histogram</i> |
| RNA | Rede Neural Artificial |
| ROI | <i>Region of interest</i> (Região de interesse) |
| SGLD | <i>Spatial Grey Level Dependency</i> |
| SVM | <i>Support Vector Machine</i> |
| VT | <i>Voting tree</i> |

Capítulo 1 INTRODUÇÃO GERAL

O câncer de mama é considerado um problema global, ocorrendo em larga escala tanto em países desenvolvidos quanto em países subdesenvolvidos (SIEGEL *et al.*, 2015). Este tipo de câncer é o segundo mais frequente no mundo e o mais comum entre mulheres, correspondendo em 1 a cada 10 novos casos de câncer diagnosticados na população mundial (FERLAY *et al.*, 2010).

No Brasil, é a doença com maior grau de mortalidade em mulheres, na maioria das vezes devido ao estágio avançado da doença, decorrente do diagnóstico tardio. Foram estimados mais de 57 mil novos casos de câncer de mama no ano passado, com um risco estimado de 56.09 casos para cada 100 mil mulheres brasileiras. No entanto, mediante a realização de diagnósticos e tratamentos oportunos, o prognóstico da doença pode ser bom (INCA, 2014).

Tabár, Tot e Dean (TABÁR, TOT, DEAN, 2005) apoiam a teoria de que, antes de tornar-se sistêmico, o câncer de mama fica limitado à mama por um tempo variável. Sendo assim, a mamografia é o principal recurso para o diagnóstico precoce, influenciando diretamente na taxa de mortalidade e até na possibilidade de cura da doença.

Análises de alguns estudos encontraram uma redução na taxa de mortalidade de 16 a 35% entre mulheres de 50 a 69 anos de idade que foram submetidas à mamografia, enquanto que mulheres de 40 a 49 anos de idade tiveram redução significativa de 15 a 20% na taxa de mortalidade quando foram submetidas ao exame nesta faixa etária (PISANO *et al.*, 2005; SENIE *et al.*, 1994).

Um fator que influencia diretamente na qualidade da imagem radiológica e, consequentemente na exatidão do diagnóstico é a densidade mamária. A dificuldade em analisar mamogramas de mamas densas, segundo Jackson *et al.* (JACKSON *et al.*, 1993) se deve a fatores físicos: as lesões mamárias têm propriedade de atenuação de raios X similares àquelas de tecidos glandulares e fibrosos, o que torna sua detecção mais difícil. A mama radiograficamente densa também produz mais radiação espalhada, resultando em menor contraste na imagem, além de ser difícil de expor todas as suas áreas devido à heterogeneidade dos tecidos.

Vários estudos comprovam a relação direta entre a densidade mamária e o risco de se contrair câncer de mama (BYNG *et al.*, 1998; MCCORMACK, SILVA, 2006; BOYD *et al.*, 2007; VACHON *et al.*, 2007; SCHREER, 2009; PINSKY, HELVIE, 2010; VARGHESE *et al.*, 2012). Isso significa que o tipo de tecido da mama influencia no surgimento de tal enfermidade, visto que mulheres com mamas com predominância de tecido fibroglandular (mama densa) apresentam um risco de câncer de mama de 4 a 6 vezes maior quando comparado com mulheres de mama gordurosa (BOYD *et al.*, 2007; YAGHJYAN *et al.*, 2011).

O tipo de tecido predominante da mama difere muito entre as pacientes, e está diretamente relacionado não só com o biótipo de cada paciente, mas também com fatores genéticos, hormonais, entre outros, influenciando na condução dos exames de rotina (RIASCOS, 1999).

O grau de densidade que uma mama apresenta é um problema para ser determinado, sendo uma característica importante para os especialistas durante o laudo. No entanto, essa classificação da mama por densidade mamária, além de depender dos fatores fisiológicos das estruturas visualizadas e das características técnicas dos sistemas de imagem, é um processo meramente visual e dependente da experiência do profissional (PIRES, 2007). Dessa forma, esta avaliação torna-se bem subjetiva, mesmo com o atual sistema BI-RADSTM de padronização de laudos.

1.1 Objetivo

O objetivo geral deste trabalho é classificar imagens mamográficas em quatro padrões de densidade mamária, seguindo a classificação BI-RADSTM, a partir de atributos extraídos do histograma e descritores de textura das imagens.

1.2 Objetivos Específicos

Os objetivos específicos deste trabalho são:

- Avaliar e comparar a influência dos atributos extraídos do histograma e de textura em diferentes tipos de imagem;
- Avaliar a técnica de *k-means* tanto como método de seleção de atributos, quanto como técnica de classificação de imagens;

- Testar a acurácia de redes neurais artificiais como método de classificação de imagens;
- Quantificar o número de erros do classificador e entre quais classes ocorrem o maior número de confusões.

1.3 Justificativa

O perfil demográfico brasileiro vem se alterando, consequência da crescente industrialização das cidades, urbanização da população, e principalmente dos avanços tecnológicos. Esse processo de mudança demográfica, denominado de “envelhecimento” da população, alterou a incidência das doenças e óbitos em uma população, reduzindo a ocorrência de doenças infectocontagiosas, porém aumentando a incidência de doenças crônico-degenerativas (INCA, 2014).

A transição e a vigilância epidemiológica foram então reformuladas, incluindo hoje o grupo de doenças crônico-degenerativas no repertório tradicional da vigilância epidemiológica. A vigilância do câncer, por exemplo, é destinada a produzir informações para a tomada de decisões, visto que, o desenvolvimento da maioria dos cânceres, necessita de múltiplas etapas que ocorrem ao longo de muitos anos (INCA, 2014).

Tendo em vista que as imagens de diferentes classes de densidade mamária possuem características diferentes, o uso de atributos extraídos do histograma e descritores de textura vem sendo utilizados para diferenciar essas imagens (CUZICK *et al.*, 2004; PETROUDI, KADIR, BRADY, 2003; MANDUCA *et al.*, 2009; KALLENBERG *et al.*, 2011). Isso significa que imagens de diferentes padrões de densidade mamária são representadas por diferentes tecidos, e, portanto, possuem características distintas, ou seja, as classes devem possuir atributos diferentes entre si.

Como a classificação de exames mamográficos por densidade mamária é um processo visual e que depende fortemente da experiência do profissional, torna-se necessário o desenvolvimento de ferramentas mais precisas e confiáveis que possam auxiliar os médicos radiologistas na interpretação das imagens mamográficas, sobretudo na classificação por padrões de densidade mamária.

Assim, o diferencial deste trabalho será a classificação de atributos a partir de combinação de diferentes tipos de atributos: extraídos de histograma e descritores de textura de Haralick e a comparação destes atributos em diferentes imagens.

1.4 Estrutura da Dissertação

Além deste Capítulo introdutório, que apresenta a motivação, justificativa e os objetivos a serem alcançados, o texto será dividido estruturalmente da seguinte forma:

- **Capítulo 2:** Conceitos sobre mamografia, evolução da caracterização por padrões de densidade mamária, padronização e classificação de laudos mamográficos.
- **Capítulo 3:** Apresentação do estado da arte da classificação de imagens por densidade mamária.
- **Capítulo 4:** Descrição de análise e processamento de imagens, descrevendo técnicas de: extração e seleção de atributos, além da classificação de imagens.
- **Capítulo 5:** Descrição da metodologia utilizada para a extração e seleção de atributos, além da classificação das imagens. Em um primeiro momento essas análises foram feitas para imagens em filme, e posteriormente, para imagens digitais.
- **Capítulo 6:** Análise e apresentação dos resultados obtidos para as etapas de extração e seleção dos atributos, tanto das imagens em filme, quanto para as imagens digitais.
- **Capítulo 7:** Resultados obtidos para os dois testes de classificação das imagens, além da quantificação do número de erros cometidos pelas etapas de classificação.
- **Capítulo 8:** Apresentação das conclusões finais, bem como propostas para trabalhos futuros que podem ser realizados a partir dessa pesquisa.

Capítulo 2 MAMOGRAFIA E DENSIDADE MAMÁRIA

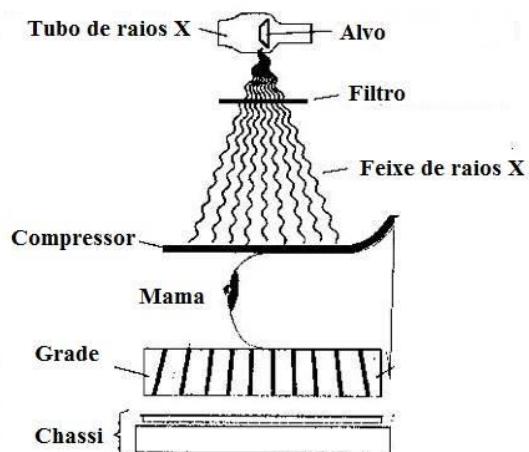
Este Capítulo é reservado para explicar conceitos gerais de mamografia, o que representa a densidade mamária e a evolução da classificação de imagens por densidade mamária.

2.1 Conceitos gerais de mamografia

A mamografia é um tipo de exame por imagem radiográfica e um dos mais eficazes métodos para rastreamento e detecção do câncer de mama, reduzindo a mortalidade em até 30%. A sensibilidade da mamografia varia entre 88% e 93,1% e a especificidade entre 85% e 94,2%. O exame de mamografia tem como objetivo a produção de uma imagem com qualidade, utilizando-se da menor dose possível de radiação (KOPANS, 2000).

Antigamente os equipamentos radiográficos convencionais eram os responsáveis pela geração de imagens mamográficas, até que com a evolução da tecnologia e a inserção de novos acessórios surgiu o mamógrafo, dedicado exclusivamente para a mamografia. O mamógrafo nada mais é que um aparelho de raios X diferenciado que obtém uma imagem a partir de diferenças de coeficiente de atenuação linear dos diversos tipos de tecidos e materiais, detectando estruturas de diferentes densidades e formas (WHITMAN, HAYGOOD, 2012). A Figura 2.1 exemplifica o esquema de um mamógrafo.

Figura 2.1 – Sistema mamográfico.



Fonte: Modificado de (WOLBARST, 1993).

A imagem mamográfica é obtida através da detecção dos raios X que atravessam o tecido mamário que é comprimido. Os raios X são produzidos em um elemento chamado tubo de raios X, conforme exemplificado na Figura 2.1. Esse elemento consiste em dois eletrodos submetidos à vácuo, no qual é aplicado uma tensão entre eles de forma a gerar um campo elétrico.

O cátodo, eletrodo negativo, formado por um filamento de alto ponto de fusão, possui um elemento resistivo que libera elétrons a partir da passagem de corrente elétrica. Tais elétrons são acelerados até colidirem com o eletrodo positivo (anodo). Na extremidade do anodo é onde fica o alvo, revestido em geral por molibdênio, ródio, ou tungstênio, no qual possui uma pequena área denominada ponto focal, onde efetivamente é produzida a radiação (WOLBARST, 1993).

O filtro é responsável por impedir e retirar fótons de baixa energia do feixe de raios X, que nada contribuiriam para a formação da imagem, evitando assim que a paciente receba desnecessariamente uma maior dose de radiação. Por outro lado, fótons de energia maior que 20 kEv também são filtrados (HAUS, YAFFE, 2000).

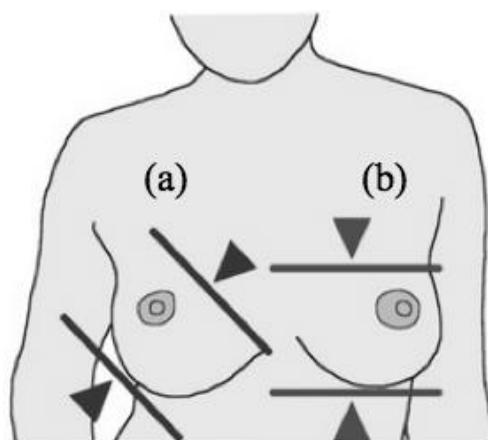
Durante o exame ocorre a compressão da mama, aspecto bastante importante, visto que com uma menor espessura do objeto em estudo, ocorre uma diminuição da radiação espalhada, e por consequência em um menor borramento da imagem. Outra finalidade da compressão é imobilizar a mama e possibilitar que a região de interesse fique mais próxima do detector da imagem, evitando assim a sobreposição de tecidos (POULOS *et al.*, 2003).

Em alguns equipamentos é possível que exista uma grade móvel, colocada entre o suporte da mama e o compartimento para a colocação do chassi, que visa reduzir o ruído devido à diminuição da radiação espalhada. Ademais em alguns sistemas mamográficos, observa-se a existência do controle automático de exposição, AEC (*Automatic Exposure Control*), que automaticamente controla a quantidade de radiação necessária para a formação de uma imagem adequada (HAUS, YAFFE, 2000).

Diante do conhecimento da anatomia da mama, os equipamentos permitem a utilização de técnicas de posicionamento, a fim de explorar melhor a mama. A incidência ou vista médio-lateral oblíqua (MLO), por exemplo, permite mostrar toda a mama em apenas uma imagem, desde que o receptor de imagem do equipamento esteja paralelo ao plano muscular, expondo ao máximo tecido mamária e axilar. Já a outra incidência, denominada crânio-caudal (CC), complementa a MLO, pois visa incluir todo o tecido póstero-medial, que

não é visualizado na imagem sob vista MLO (MITCHELL, BASSETT, 1988). A Figura 2.2 apresenta essas posições de exposição.

Figura 2.2 – Posições de exposição para exames mamográficos. (a) Incidência MLO. (b) Incidência CC.



Fonte: Modificado de (ROSE, 2005).

Apesar da alta sensibilidade da mamografia, existem estudos que mostram perda de 10% a 15% dos casos de câncer detectável no exame clínico. Isso acontece geralmente nos casos de mamas densas, característica presente, geralmente, em mulheres mais jovens. Esse tipo de mama ainda é um problema para o diagnóstico precoce do câncer, visto que há pequena variação de contraste entre os achados e os tecidos adjacentes que compõem a mama (KOPANS, 2000; DORGAN, 2012).

A mamografia, mesmo que possua um feixe de raios X menos energético, as doses de radiação ainda são consideradas altas, visto que é utilizado um baixo valor de tensão e alto valor de corrente (aumentando-se a corrente, aumenta-se a intensidade do feixe) (HAUS, YAFFE, 2000). Já uma maior tensão aplicada ao tubo, gera uma maior energia aos raios X e consequentemente, um aumento no poder de penetração.

Nos próximos tópicos serão apresentadas as características referentes à mamografia convencional e digital, diferindo-se principalmente pelo sistema de registro da imagem. A primeira utiliza um filme para a visualização da imagem após a exposição da mama aos raios X, enquanto que na mamografia digital é usado um detector que transforma os raios X em sinal elétrico, sendo transmitido a um computador.

2.2 Mamografia convencional

A mamografia convencional (tela-filme) ainda é utilizada em alguns programas de rastreamento do câncer de mama. Neste tipo de equipamento, é usado um filme para visualização da imagem após a exposição da mama. Os fótons atravessam o tecido mamário e chegam ao chassi do filme pela sua base, atingindo a tela. Nesse momento, a energia é convertida em luz visível, sendo refletidos de volta para impressionar o filme, produzindo assim a imagem mamográfica (YOUNG, WALLIS, RAMSDALE, 1994). Neste sistema, o filme radiográfico é utilizado não só como detector dos raios X, mas também como meio de armazenamento e exibição da imagem.

Apesar da alta resolução espacial dos filmes usados na mamografia convencional (entre 12 a 15 pares de linha por milímetro), essa resolução fica limitada à baixa capacidade de distinguir estruturas com pouca diferença de contraste, isto é, fica difícil diferenciar elementos com coeficientes de absorção de raios X similares (ROBSON, KOTRE, FAULKNER, 1995).

Neste tipo de exame, o tempo médio de revelação do filme é cerca de 3 minutos, e caso a imagem não fique satisfatória para análise e interpretação do especialista, é necessário que a paciente repita todo o procedimento, acarretando em alguns problemas, principalmente no *recall* da paciente, se tornando muitas vezes demorado, devido à revelação do filme. A Figura 2.3 retrata uma imagem obtida de uma mamografia convencional.

Figura 2.3 – Exemplo de uma imagem de mamografia convencional sob vista médio-lateral.



Fonte: (SUCKLING *et al.*, 1994).

2.3 Mamografia digital

Desde o surgimento da mamografia digital, este sistema ganhou popularidade em comparação ao sistema tela-filme devido a algumas vantagens, tais como: eliminação da revelação do filme, possibilidade de cópias e recuperação de imagens armazenadas, manipulação da imagem e detecção assistida por computador. Dentre as desvantagens, destaca-se o alto custo e a dificuldade de comparação com imagens obtidas do sistema convencional de tela-filme (PISANO, YAFFE, 2005).

Nos mamógrafos digitais são utilizados detectores que transformam os raios X em sinal elétrico, e esse sinal é convertido à uma imagem digital por meio de um conversor A/D, deixando de se utilizar então os filmes. Dentre os sistemas digitais, existem duas modalidades: o sistema CR (*Computed Radiography*) e o sistema FFDM (*Full Field Digital Mammography*).

Nos sistemas CR é usado uma placa de fósforo, *Image Plate* (IP), responsável por armazenar os raios X residuais. Após a exposição, o IP é introduzido em uma leitora que faz a liberação da energia armazenada, convertendo o sinal analógico em digital a partir de um conversor A/D, sendo então interpretado por um computador em linguagem binária (ROWLANDS, 2002).

Já no sistema digital de campo total (FFDM) a leitura dos raios X é feita imediatamente, sendo transmitida diretamente a um computador. O diferencial dos sistemas FFDM são os tipos de detectores que ele pode possuir: direto e indireto.

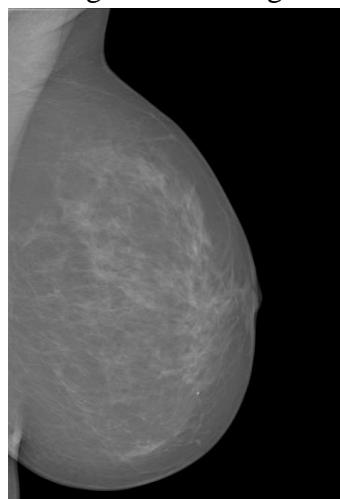
No detector direto, o espalhamento do feixe luminoso é eliminado, fazendo com que o fotocondutor absorva os raios X e converta-os diretamente em sinal digital mediante um conversor A/D. A tecnologia de selênio amorfo utilizado neste tipo de sistema oferece alta eficiência quântica e alta resolução, além de satisfazer condições necessárias para que ele seja utilizado em sistemas de imagem por raios X, tais como: alta resistência, baixo ruído, boa fotossensibilidade e acessível quanto ao processo de produção (SMITH, 2003).

Já no detector indireto o processo se baseia em duas etapas. Na primeira etapa, a energia em forma de raios X é capturada por um cintilador e a transforma em fótons de luz. Em seguida, uma matriz com diodos de filme fino transforma esses fótons de luz em sinal eletrônico, sendo posteriormente capturados por transistores de filme fino. Neste tipo de

detector, o espalhamento do feixe luminoso faz com que a qualidade da imagem seja comprometida (SMITH, 2003).

Com a crescente utilização dos sistemas digitais nos programas de rastreamento de câncer de mama, a principal preocupação é com relação à resolução espacial limitada (5 a 10 pares de linha por milímetro). Entretanto esse tipo de sistema possui melhor resolução de contraste em comparação ao sistema tela-filme (DERSHAW, 2005). A Figura 2.4 apresenta um exemplo de imagens deste tipo de equipamento.

Figura 2.4 - Exemplo de uma imagem de mamografia digital sob vista médio-lateral.



Fonte: (MOREIRA *et al.*, 2012).

A imagem digital, conforme representando pela Figura 2.4, é definida como uma função bidimensional $f(x,y)$, em que x e y correspondem às coordenadas espaciais, e a amplitude de f é o nível de cinza da imagem naquela determinada coordenada. Quando os valores de x , y e f são números finitos (discretos), a imagem é chamada de digital (GONZALEZ, 2009).

Neste trabalho serão feitos testes tanto com imagens provenientes dos equipamentos de 1^a geração, tela-filme (imagens em filme), quanto com imagens de sistema de mamografia digital FFDM (imagens digitais).

2.4 Densidade mamária e padronização da classificação

A densidade da mama é um fator decisivo na qualidade da imagem radiológica e, consequentemente, na exatidão do diagnóstico. Ela corresponde ao tipo de tecido predominante da mama, sendo que quanto maior a densidade da mama, maior a predominância de tecido fibroglandular em sua composição. O tecido denso é encontrado em uma maior frequência em mulheres com menos de 40 anos de idade, e com uma frequência decrescente em mulheres com idade superior a 50 anos (YAFFE, 2008).

A densidade mamária está fortemente relacionada com o risco do desenvolvimento do câncer de mama. Quanto maior a densidade mamária, maior a chance da não detecção ou de uma detecção tardia de tumores malignos (SAFTLAS *et al.*, 1991; KATO *et al.*, 1995; BYNG *et al.*, 1998; VARGHESE *et al.*, 2012). Isso se deve ao fato que o tecido fibroglandular aparece em tons mais claros (branco) na imagem, o que pode dificultar a visualização de alguns tumores que apresentam níveis de cinza similares a tal tecido, resultado do baixo contraste em imagens de mamas densas (BAKIC *et al.*, 2009).

A seguir será apresentada a evolução das classificações de densidade mamária (composição mamária), desde a década de 70 até a versão mais recente utilizada nos dias atuais. Com o passar dos anos buscou-se diminuir a subjetividade da classificação, tentando transformar a análise em algo mais quantitativo que qualitativo.

Wolfe, de forma pioneira em 1976 (WOLFE, 1976), propôs uma classificação em quatro categorias que se baseia na proporção de tecido adiposo, conectivo e epitelial e de ductos proeminentes observados na mamografia, descrevendo então a densidade mamária de acordo com a substituição adiposa e a proeminência dos ductos:

- **N1:** parênquima composto basicamente por gordura, sem ductos visíveis;
- **P1:** parênquima composto principalmente por gordura, com ductos proeminentes na porção anterior, ocupando até $\frac{1}{4}$ do volume da mama;
- **P2:** padrão ductal proeminente ocupando mais de $\frac{1}{4}$ do volume da mama;
- **DY:** parênquima denso, obscurecendo um padrão ductal proeminente.

A partir dessa categorização pode-se dizer que as categorias N1 e P1 apresentam baixo risco de se desenvolver câncer de mama, sendo que a P2 e a DY apresentam alto risco por serem mamas consideradas densas. Uma quinta categoria foi adicionada posteriormente, **Qdy**, representado por mulheres jovens que apresentam mamas densas com textura esponjosa.

Como alternativa à classificação de Wolfe, Boyd e colaboradores (BOYD *et al.*, 1995) sugeriram uma classificação quantitativa da densidade mamária, levando em consideração a porcentagem de tecido fibroglandular da mama. Foram criadas seis categorias, sendo que, a categoria A representa a mama totalmente constituída por tecido adiposo (não densa) e a categoria F, mamas consideradas densas, com mais de 75% do seu volume constituído de tecido fibroglandular.

- **A:** 0% de tecido fibroglandular;
- **B:** > 0-10% de tecido fibroglandular;
- **C:** > 10-25% de tecido fibroglandular;
- **D:** > 25-50% de tecido fibroglandular;
- **E:** > 50-75% de tecido fibroglandular;
- **F:** > 75% de tecido fibroglandular.

Em seguida, surgiu a classificação de Tabár (GRAM, FUNKHOUSER, TABÁR, 1997), que propõe descrever a composição mamária em quatro elementos principais, sendo eles: densidade nodular, densidade linear, homogeneidade de tecido fibroglandular e tecido adiposo radioluscente. A classificação foi dividida em cinco padrões, apresentados a seguir:

- **Padrão I:** composto de 25%, 16%, 35% e 24% dos quatro elementos, respectivamente;
- **Padrão II:** tem aproximadamente: 2%, 14%, 2% e 82% dos quatro elementos, respectivamente;
- **Padrão III:** similar ao Padrão II, exceto o fato de que os ductos retroareolares proeminentes são associados à fibrose periductal na mama;
- **Padrão IV:** é predominantemente composto por densidades nodulares e lineares, com aproximadamente 49%, 49%, 15% e 17% dos elementos, respectivamente;
- **Padrão V:** é predominante composto por tecido fibroglandular, sendo composto por 2%, 2%, 89% e 7% dos quatro elementos, respectivamente.

Os padrões I, II e III correspondem às mamas com menos risco de se desenvolver câncer de mama, enquanto que os padrões IV e V estão relacionados a mamas com maior risco.

2.4.1 Breast Imaging Reporting and Data System (BI-RADS™)

Em 1993, um estudo colaborativo entre membros de vários comitês do *American College of Radiology* (ACR), com colaboração do *National Cancer Institute, Centers for Disease Control and Prevention, Food and Drug Administration* (FDA), *American Medical Association, American College of Surgeons*, e o *College of American Pathologists* produziu a primeira edição do **Breast Imaging Reporting and Data System (BI-RADS™)**.

O objetivo dessa sistematização é padronizar a nomenclatura dos laudos, melhorando a comunicação entre os diferentes profissionais da saúde, reduzir eventuais erros de interpretação, ajudar na pesquisa, facilitar no monitoramento dos resultados, além de evitar possíveis ambiguidades (EBERL *et al.*, 2006; HONG *et al.*, 2005; TAPLIN *et al.*, 2002).

A partir da segunda metade da década de 1990, a conduta tornou-se obrigatória, por lei federal, nos Estados Unidos, sendo que no Brasil, esse modelo foi adotado como consenso e vem sendo cada vez mais utilizado.

Além da classificação da mama em achados, o BI-RADS™ também propõe uma classificação em padrões de densidade mamária. Em 1998 (ACR, 1998), o Colégio Americano de Radiologia lançou a terceira edição do BI-RADS™, em que os padrões de densidade variavam de I à IV, conforme apresentado a seguir:

- **I:** a mama é inteiramente gordurosa;
- **II:** a mama possui áreas de tecido fibroglandular dispersas;
- **III:** a mama é heterogeneamente densa;
- **IV:** a mama é inteiramente densa.

Neste trabalho, entretanto, foi utilizada a classificação proposta pela quarta edição do BI-RADS™ (D'ORSI *et al.*, 2003), na qual afirma que a composição mamária está relacionada com as quantidades relativas (porcentagem) de tecido adiposo e fibroglandular. As quatro categorias do BI-RADS™ usadas neste trabalho são:

- **1:** Mamas predominantemente adiposas (25% do componente fibroglandular);
- **2:** Mamas parcialmente gordurosas (com densidades de tecido fibroglandular ocupando de 26% a 50% do volume da mama);
- **3:** Mamas com padrão denso e heterogêneo (51% a 75% de tecido fibroglandular, dificultando a visibilidade de nódulos);

- **4:** Mamas muito densas, apresentando mais de 75% de tecido fibroglandular (diminuindo a sensibilidade da mamografia).

Mais recentemente, em 2013, foi lançada a quinta e mais nova edição do BI-RADS™ (SICKLES *et al.*, 2013), que desencoraja o uso de porcentagem para classificação, assimilando-se à terceira edição e substituindo os números da versão anterior por letras. A categoria 1 foi substituída por “a”, a categoria 2 por “b” e assim sucessivamente, conforme apresentando a seguir:

- **a:** a mama é quase inteiramente composta por tecido adiposo. A mamografia é altamente sensível para este tipo de mama;
- **b:** há áreas dispersas de tecido fibroglandular.
- **c:** a mama é heterogeneamente densa, podendo obscurecer pequenas massas;
- **d:** a mama é quase inteiramente composta por tecido fibroglandular. A sensibilidade da mamografia é reduzida para este tipo de mama.

Vale ressaltar que as imagens processadas neste trabalho foram laudadas a partir da versão anterior (quarta edição) do BI-RADS™, visto que o banco de dados utilizados neste trabalho e a maioria dos existentes são classificados a partir desta edição. Tal fato não altera o objetivo geral do trabalho, até porque, a nova edição só retira o aspecto quantitativo (porcentagem) da versão anterior, e, sendo uma versão bem recente ainda, levará tempo para ser usada na avaliação das imagens dos bancos digitais.

Capítulo 3 ESTADO DA ARTE

Este Capítulo é destinado à apresentação de trabalhos de diferentes pesquisadores, descrevendo a metodologia usada para classificar imagens por densidade mamária, bem como os resultados e contribuições desses estudos.

3.1 Classificação de imagens por densidade mamária

Neste Capítulo serão apresentados alguns trabalhos relevantes relacionados à classificação de imagens mamográficas por densidade mamária. Inicialmente serão apresentados alguns trabalhos pioneiros, desde a classificação de imagens em tela-filme, até estudos recentes, feitos em imagens digitais com diversas técnicas de classificação.

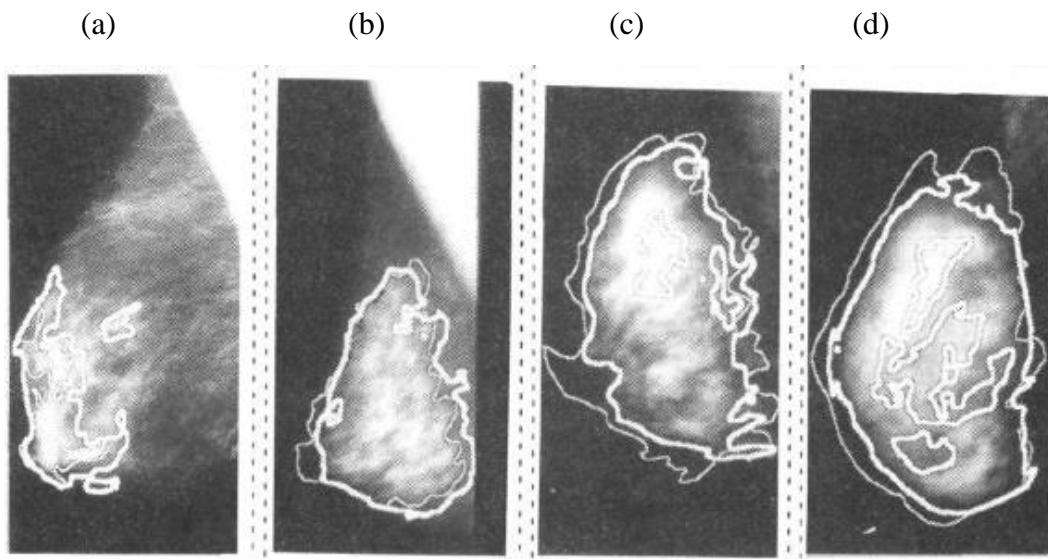
A classificação de imagens por densidade mamária vem sendo estudada há vários anos, principalmente pela relação entre a densidade mamária e o risco de se desenvolver câncer de mama, conforme explicado no Capítulo anterior. No entanto, nos primeiros estudos relacionados a este tema, a ideia de identificar o tipo de tecido da mama era com o objetivo de avaliar a assimetria entre mama direita e mama esquerda, além de estimar o risco de radiação absorvida durante os exames mamográficos.

Miller e Astley (MILLER, ASTLEY, 1992), no início da década de 90 propuseram, de maneira pioneira, a identificação de tecido mamário fibroglandular pela análise de textura. Neste trabalho optou-se pela classificação a partir de técnicas de granulometria para a análise da textura das imagens mamográficas, além de medidas de energia de Laws.

Os resultados da classificação automática proposta no trabalho foram comparados com a avaliação dada por dois radiologistas experientes. As imagens mamográficas em filme foram laudadas em três classes: mama gordurosa, mama gordurosa-glandular e mama glandular (densa). Para o conjunto de 40 mamogramas analisados, foi obtido 80% de acerto com o classificador automático a partir das medidas de energia de Laws, que se mostraram superiores às técnicas de granulometria.

A Figura 3.1 compara as regiões de tecido fibroglandular encontradas pelos radiologistas e pelo método automático, sendo que a linha mais grossa (mais branca) corresponde ao traçado feito pelos médicos.

Figura 3.1 – Comparação entre as regiões de tecido fibroglandular encontradas pelos residentes (traçado mais grosso) e pelo método automático (traçado mais fino). (a) Mama gordurosa. (b) Mama gordurosa-glandular. (c) Mama glandular. (d) Mama glandular com baixo índice de acerto.



Fonte: (MILLER, ASTLEY, 1992).

Dois anos depois, em 1994, Taylor e colaboradores (TAYLOR *et al.*, 1994), seguindo a linha do trabalho anterior, investigaram técnicas computadorizadas para classificar mamografias de acordo com o tecido mamário. A hipótese é de que mamas densas dificultam a interpretação da mamografia tanto por parte do radiologista, quanto pelo computador. Automatizar a tarefa de identificação de mamas densas permitiria uma otimização do tempo e das habilidades dos médicos, repassando estes exames mais complexos para radiologistas mais experientes.

Os mamogramas utilizados neste trabalho foram classificados independentemente por dois radiologistas, que concordaram na maioria dos casos. Uma série de medidas estatísticas e de textura foram extraídas de regiões de interesses (ROI) dos mamogramas, sendo incorporadas a um sistema automatizado que conseguiu separar aproximadamente dois terços de mamografias com predominância de tecido gorduroso.

Karssemeijer (KARSSEMEIJER, 1998) utilizou 615 imagens em filme digitalizados do banco de dados Nijmegen para testar a performance do método proposto para a classificação da densidade mamária. A segmentação foi feita de acordo com um limiar global e remoção do músculo peitoral por aproximação (linha reta). O mapeamento de distância e o cálculo do histograma foram aplicados em diferentes distâncias de acordo com a interface ar/pele da mama. Foi extraído um conjunto de oito atributos, inclusive desvio padrão e assimetria,

calculados a partir de histogramas e da comparação da densidade do tecido com a densidade do músculo peitoral. Foi utilizado o classificador k-vizinho mais próximo (k-NN) obtendo um resultado de aproximadamente 66% de acerto.

A partir dos anos 2000, houve uma crescente tendência de utilização de sistemas computadorizados de auxílio ao diagnóstico, os chamados sistemas CAD (*Computer-aided diagnosis*), que a partir de algoritmos computacionais, surgem para auxiliar os profissionais durante a interpretação dos exames. Esses sistemas não devem ter o propósito de diagnóstico, mas sim de proporcionar ferramentas que facilitem o diagnóstico, que deve ser feito exclusivamente pelos especialistas.

A maioria dos estudos até então, vinham extraindo, sobretudo, atributos de textura das imagens mamográficas, até que Zhou e outros pesquisadores (ZHOU *et al.*, 2001) decidiram trabalhar com atributos baseados em histograma. A ideia era desenvolver uma ferramenta de análise de imagens capaz de estimar a densidade mamária. Foram utilizados 260 mamogramas em filme, de 65 pacientes sob as vistas MLO e CC, tanto de mama direita como de mama esquerda.

A análise da composição mamária dos mamogramas se deu na criação de três etapas. Na primeira etapa, a região da mama era segmentada do fundo por um algoritmo de detecção de borda. A segunda etapa consistia em uma técnica adaptativa de compressão da faixa dinâmica que era aplicada à imagem de forma a reduzir o intervalo da distribuição de níveis de cinza das baixas frequências (*background*) e aumentando as diferenças entre os níveis de cinza dos histogramas das imagens de mamas de diferentes densidades. Na última etapa, a classificação foi feita a partir das quatro classes propostas pela terceira edição do BI-RADSTM, a partir de atributos dos histogramas das imagens. A Figura 3.2 ilustra esses passos.

Figura 3.2 – (a) Exemplo de mamogramas usado no trabalho. (b) Mama com o limite e o músculo peitoral detectado. (c) Mapa binário da imagem segmentada apenas com região mamária.

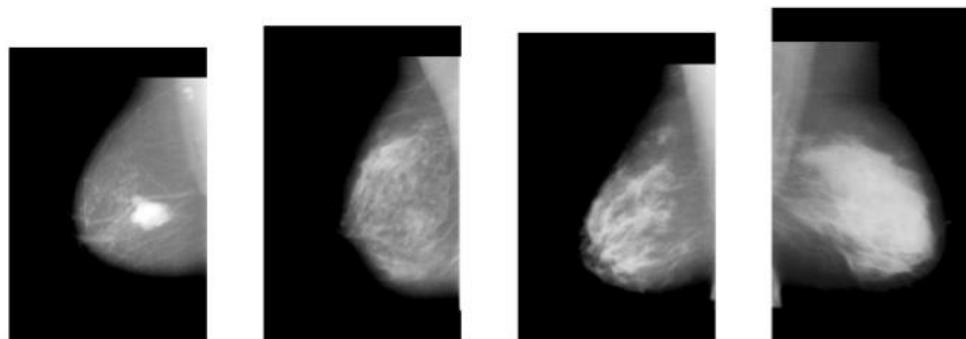


Fonte: (ZHOU *et al.*, 2001).

Para cada imagem, um limiar (*threshold*) de nível de cinza foi automaticamente determinado, de forma a segmentar o tecido denso e a região da mama. A área de tecido denso segmentado da mama é então estimada. A fim de avaliar a performance do algoritmo, a segmentação feita pelo computador foi comparada com a segmentação manual feita por cinco radiologistas, com diferença de segmentação em apenas 6% das imagens. Para as imagens que foram corretamente segmentadas, a classificação por meio do classificador *rule-based histogram* (RBH) obteve 94% e 91% de acertos nas imagens sob vistas CC e MLO, respectivamente.

A partir destes estudos e da importância de classificar as mamas corretamente, Bovis e Singh (BOVIS, SINGH, 2002), propuseram a classificação de imagens mamográficas tanto nas quatro classes propostas pelo BI-RADS™, quanto em duas classes (tecido gorduroso e tecido denso). Foram utilizadas 377 imagens em filme digitalizadas em 8 bits (256 níveis de cinza), exemplificado pela Figura 3.3.

Figura 3.3 – (a) Mama predominantemente adiposa. (b) Mama com pouco tecido fibroglandular. (c) Mama heterogeneamente densa. (d) Mama extremamente densa.



Fonte: (BOVIS, SINGH, 2002).

Destas imagens foram extraídos quatro conjuntos de atributos de textura de Haralick, a partir da construção de matrizes de distribuição de dependência espacial dos níveis de cinza (*Spatial Grey Level Dependency* - SGLD) nas direções 0°, 45°, 90°, 135° nas distâncias de pixel {2, 4 e 6}. Após a extração de atributos, foi utilizado Análise de Componentes Principais (*Principal Component Analysis* – PCA) com o intuito de reduzir as dimensões do conjunto de dados.

A classificação foi feita usando Rede Neural Artificial (RNA), na qual 90% do conjunto de imagens foi usado para treinamento e 10% para teste. Os melhores resultados foram obtidos quando a classificação ocorria em apenas duas classes e não em quatro. Foi

mostrado também que a combinação de atributos se mostrou melhor do que a utilização de um único atributo, com 96,7% de acerto na classificação em duas classes de densidade mamária. Para a classificação em quatro classes, o acerto foi de 71,4%.

A partir do trabalho de Boyd (BOYD *et al.*, 1995) que promoveu um sistema computadorizado automático quantitativo de medida de densidade mamária, Petroudi, Kadir e Brady (PETROUDI, KADIR, BRADY, 2003) desenvolveram um estudo de classificação automática dos padrões de parênquimas mamários. A abordagem do trabalho é de que as texturas extraídas das classes nada mais são que distribuições estatísticas (histogramas), e a classificação nada mais é do que uma comparação desses histogramas utilizando uma medida de distância apropriada.

Foram usadas 132 imagens em filme da *Oxford Database*, laudadas a partir da terceira edição do BI-RADSTM, apenas sob vista MLO. Cada mamograma foi segmentado em três componentes distintas: fundo, tecido mamário e músculo peitoral. Também foi desenvolvido um algoritmo automático de segmentação da mama que identifica com precisão a “borda” da mama, bem como remove o músculo peitoral.

Após a etapa de segmentação, ocorre a filtragem da área correspondente à mama, no qual foi utilizado o banco de filtragem de “Maximum Response 8 (MR8)” proposto por (VARMA, ZISSERMAN, 2002). A classificação foi feita a partir da técnica de *k-means*, obtendo uma taxa média de acerto de 75%, sendo que para a categoria BI-RADSTM I, o acerto foi de 91%.

Como a sensibilidade da mamografia é significativamente reduzida quanto maior a densidade da mama analisada, em 2005, Oliver, Freixenet e Zwiggelaar (OLIVER, FREIXENET, ZWIGGELAAR, 2005) se basearam na ideia de que mamogramas de BI-RADSTM diferentes são representados por tecidos com textura diferentes, isto é, cada classificação BI-RADSTM deverá apresentar uma textura diferente entre elas. Dessa forma, as imagens podem ser classificadas e compor parte de um sistema CAD.

A novidade dessa abordagem é que o agrupamento de pixels de tecidos similares é utilizado como uma estratégia de segmentação. O objetivo da segmentação é extrair partes da imagem que correspondem à mama de outros objetos que podem estar presentes na imagem, tais como: fundo, anotações, músculo peitoral, tentando ao máximo manter apenas a área da mama para análise. Para a segmentação utilizou-se o algoritmo *Fuzzy C-means*, que é uma extensão do *k-means*.

Foram extraídos descritores de textura de Haralick e atributos de morfologia de 300 imagens provenientes do banco digital DDSM (*Digital Database of Screening Mammographies*), sendo 50 imagens BI-RADS™ I, 100 imagens BI-RADS™ II, 100 imagens BI-RADS™ III, e 50 imagens BI-RADS™ IV. Para a classificação foi usada a técnica de vizinhos mais próximos, k-NN (*k-Nearest Neighbors*) e árvore de decisão (ID3).

Os resultados experimentais demonstraram a eficácia da estratégia proposta, além de verificar que a combinação dos classificadores obtiveram maior taxa de acerto do que usando os classificadores individualmente.

Foram analisadas imagens do banco virtual MIAS (imagens em filme) e DDSM (imagens digitais), tanto sob vista crânio-caudal, quanto sob vista médio-lateral oblíqua no trabalho de Bosch e outros pesquisadores (BOSCH *et al.*, 2006). O objetivo era classificar o tecido mamário em imagens mamográficas, dando maior relevância à segmentação da mama, visando extrair informações e objetos irrelevantes que poderiam confundir os atributos extraídos.

Assim, optou-se pela segmentação da área útil em todos os mamogramas e a eliminação do músculo peitoral nas imagens sob vista MLO. Na primeira etapa, o algoritmo calcula um histograma de níveis de cinza para a imagem, além de um limiar automático, que é o valor mínimo desse histograma. Esse limiar é utilizado para obter uma coleção de imagens de diferentes regiões. A maior região, no caso a união da região da mama com o músculo peitoral é extraída a partir do algoritmo *Connected-Component Labeling*, resultando em uma imagem sem etiquetas, rótulos, e informações desnecessárias, obtendo assim uma imagem segmentada. Na segunda etapa, a retirada do músculo peitoral, foi usado o método proposto por (FERRARI *et al.*, 2004).

Posteriormente as imagens são, então, classificadas usando a técnica de vizinhos mais próximos (k-NN) e *Support Vector Machine* (SVM), sendo que a segunda técnica se mostrou superior à primeira, obtendo 91.39% de acerto na classificação em três classes das imagens do banco MIAS e 84.75% de acerto nas imagens do banco DDSM, classificadas em quatro classes conforme o padrão BI-RADS™.

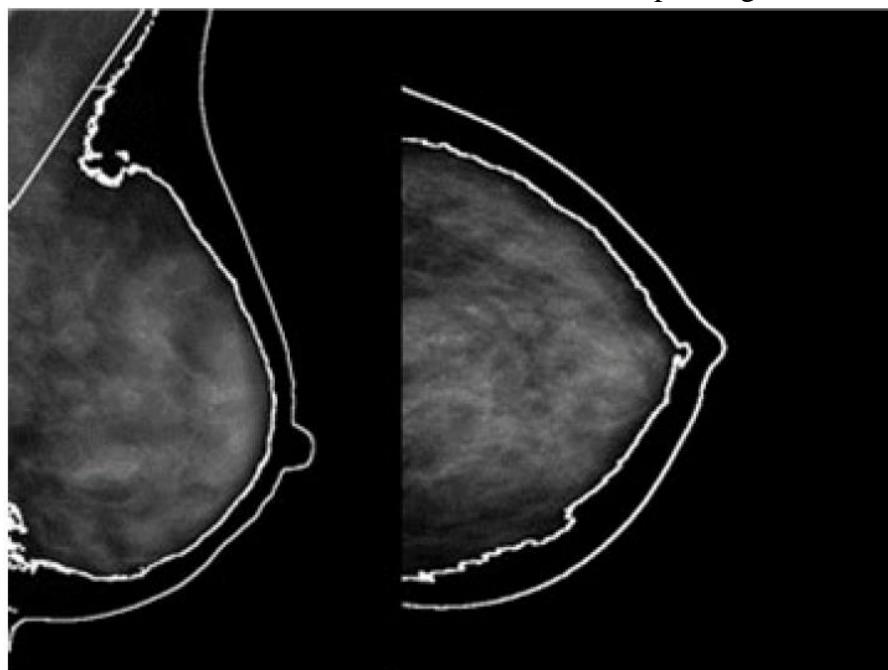
O percentual de densidade mamária é um fator de risco elevado para o desenvolvimento do câncer de mama, porém existem relativamente pouca avaliação sistemática de características em imagens mamográficas, que pode ainda prever o risco de tal enfermidade. Essa foi a justificativa de Manduca e colaboradores (MANDUCA *et al.*, 2009)

que propuseram relacionar atributos de textura com o risco de câncer de mama, em imagens digitalizadas de filme.

Com o auxílio do software *Cumulus*, a porcentagem de densidade mamária e área densa absoluta é estimada. Dois limiares são estipulados, um separando a mama do fundo, e o outro separando tecido gorduroso de tecido denso. Os atributos analisados foram: matrizes de coocorrência de Markov, análise *run-length*, atributos de Laws, decomposição *wavelet* e análise de Fourier. Os resultados mostraram que os atributos de textura em baixas frequências fornecem os mais fortes indicadores de um possível desenvolvimento de câncer de mama, comprovando a importância desse tipo de característica nas imagens mamográficas.

Em 2010, Highnam e pesquisadores (HIGHNAM *et al.*, 2010) divulgaram o VolparaTM, um software designado à medida da composição mamária. Foram coletados 2217 mamogramas digitais de Oslo, Nijmegen e da Universidade da Virginia, além de algumas images de *phantom* de forma a validar o software. A performance do novo algoritmo de detecção de bordas do software, e também a robustez em se encontrar o tecido das mamas densas podem ser ilustradas pela visualização das bordas internas e externas delimitadas pelo programa, conforme apresentado na Figura 3.4.

Figura 3.4 – Mamas densas e a borda interna encontrada pelo algoritmo do software



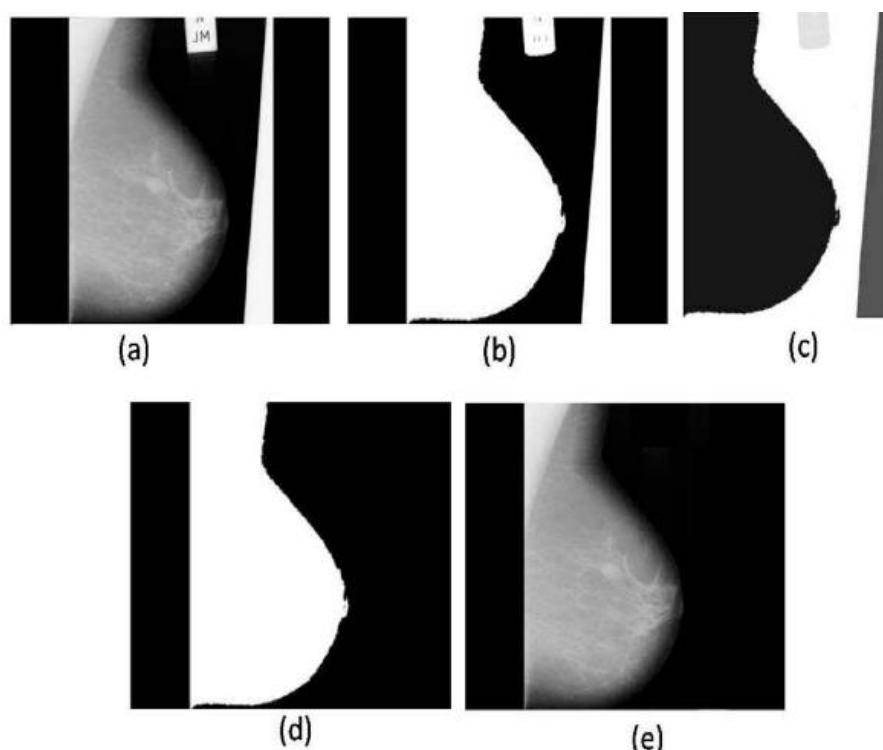
Fonte: (HIGHNAM, 2010).

Para verificar a medida da densidade mamária feita pelo software, foram usadas imagens de *phantom* com diferentes composições de tecido, e o erro médio encontrado foi de apenas 1,11%. Além disso, a acurácia do Volpara™ foi demonstrada também, comparando o resultado por ele fornecido com o cálculo manual do volume fibroglandular, e consequentemente a densidade mamária.

Subashini, Ramalingam e Palanivel (SUBASHINI, RAMALINGAM, PALANIVEL, 2010) apresentaram um trabalho intitulado: “Avaliação automática da densidade de tecido mamário em mamogramas digitalizados”. O trabalho é resumido em três etapas: pré-processamento, extração de atributos e classificação, e é feito a partir de mamogramas em filme (8 bits) digitalizados do banco de dados mini-MIAS.

Na fase de pré-processamento, ocorre a eliminação do fundo (*threshold*) e do músculo peitoral, além da eliminação de ruídos que poderiam ocasionar em uma classificação incorreta. Alguns dos atributos extraídos foram: média, desvio padrão, uniformidade e entropia. Já para a classificação foi usado *Support Vector Machine* (SVM). A Figura 3.5 retrata a etapa de segmentação da mama.

Figura 3.5 – Segmentação da mama: (a) Imagem original. (b) Segmentação do fundo. (c) Diferenciação do ruído com a área útil da mama. (d) Imagem binária sem artefatos. (e) Imagem sem artefatos.



Fonte: (SUBASHINI, RAMALINGAM, PALANIVEL, 2010).

Foram usados 43 mamogramas, ressaltando que no banco mini-MIAS, eles são laudados em três classes de densidade mamária: gordurosa, gordurosa-glandular e densa. Destas 43 imagens, 14 pertenciam à classe gordurosa, 14 à classe gordurosa-glandular e 15 à classe densa. Inicialmente foram usados 14 atributos, e depois apenas os 6 melhores, obtendo 93.02% e 95.44% de acerto com o classificador SVM.

No trabalho de Mustra, Grgic, Delac (MUSTRA, GRGIC, DELAC, 2012) tentou-se testar a eficiência da classificação de densidade mamária por um método automático usando somente atributos de Haralick e classificador k-NN. A avaliação dos atributos, assim como a seleção e classificação foi utilizando-se do Software Weka.

O experimento foi feito utilizando-se duas bases de dados a fim de comparação: mini-MIAS e banco de dados KBD-FER (Universidade de Zagreb). A diferença é que no banco mini-MIAS as imagens são de filme digitalizadas em 8 bits por pixel, ao contrário das imagens digitais de 12 bits do banco KBD-FER. Antes da extração dos atributos, foi necessária uma etapa de pré-processamento da imagem.

O processo de segmentação é feito com a mistura de limiar fixo de nível de cinza e operadores morfológicos, neste caso, erosão e dilatação. A etapa de segmentação começa com a criação da máscara binária de acordo com o limiar. Nesta etapa, todos os valores de cinza inferiores a 3 em alguns casos, e em outros 15, além superiores a 245 são removidos. A máscara binária é então erodida com um elemento estrutural quadrado de 103 x 103 pixels. O próximo passo é o redimensionamento das imagens, a fim de que toda a área da mama tenha aproximadamente o mesmo tamanho.

Depois do pré-processamento finalizado, a região de interesse (ROI) foi isolada. A ROI considerada foi apenas o disco que contém o tecido fibroglandular. O processo de redimensionamento agora se torna útil, porque não há necessidade de remoção do músculo peitoral, sendo possível observar a parte similar de disco fibroglandular de todas as mamas.

Com o processo de segmentação realizado e a região de interesse selecionada, extraíram atributos de textura de Haralick e Soh. A seleção de atributos foi realizada a partir do software Weka, que analisou diversas técnicas de seleção a fim de gerar vários conjunto de atributos para serem utilizados no classificador.

Para todos os conjuntos de atributos selecionados, foi usado o classificador k-NN para separar as imagens em densidade mamária dentre os padrões de BI-RADS™. O melhor resultado para as imagens em filme do banco mini-MIAS foi de 82,5% para a classificação em 3 classes, e 91,6% para a classificação em duas classes (Classe 1: BI-RADS™ I e II e

classe 2: BI-RADS™ III e IV). Para o banco digital de imagens, o classificador acertou em 76.4%, e 97.2%, classificando em 4 e 2 classes, respectivamente.

No estudo de Keller e colaboradores (KELLER *et al.*, 2012), foi proposta a criação de um sistema automático para quantificar tecido fibroglandular presente na mama, denominado porcentagem de densidade mamária (PD%). Até a publicação deste trabalho, a maioria das pesquisas eram com a utilização de imagens de filmes digitalizados, ao contrário desse estudo de Keller, no qual o banco de imagens é todo digital de mamógrafo FFDM. Totalizaram-se 324 imagens, de um banco de dados próprio, analisando tanto imagens *raw data*, quanto imagens processadas. A Tabela 3.1 apresenta o número de imagens analisadas de cada categoria BI-RADS™ de densidade.

Tabela 3.1 – Distribuição da quantidade de imagens *raw* e processadas utilizadas a partir das categorias BI-RADS™.

| Imagens | BI-RADS™ I | BI-RADS™ II | BI-RADS™ III | BI-RADS™ IV |
|--------------------|------------|-------------|--------------|-------------|
| Raw | 75 | 57 | 26 | 4 |
| Processadas | 69 | 73 | 16 | 4 |

A ideia era comparar as estimativas de tecidos densos indicadas pelo algoritmo automático, assim como pela PD% estimada por um radiologista. A PD% estimada pelo radiologista foi a partir do software Cumulus. Em resumo, as imagens processadas foram inicialmente janeladas pelo radiologista para uma melhor visualização e, posteriormente, a região de fundo (ar) foi excluída através de um limiar de intensidade determinado manualmente, permitindo que o limite da borda da mama fosse destacado.

A região do músculo peitoral foi também retirada por marcação manual da borda do músculo peitoral. A porção restante da imagem foi assumida como o tecido da mama, e a área total desta região é calculada pelo software. Após a identificação da área útil da mama, um segundo limiar de intensidade de tons de cinza é definido pelo usuário, a fim de definir o tom de cinza limiar entre os tecidos fibroglandular e tecido adiposo. A PD% é então calculada como a porcentagem da área do peito ocupada por tecido fibroglandular, sobre a área total da mama.

Um processo similar é utilizado para estimar a porcentagem de densidade mamária das imagens *raw*, exceto que essas imagens não são utilizadas para visualização e interpretação clínica, como é feito nas imagens processadas. O processo de segmentação para as imagens

raw foi o mesmo que para a imagem processada, descrita no parágrafo anterior, com a diferença de que nas imagens sem processamento, houve uma janelamento antes da segmentação. Duas leituras por imagem foram realizadas pelo radiologista, a cada seis meses de intervalo, e a média das duas leituras foi considerada como padrão ouro.

Para o algoritmo automático, as imagens *raw* sofreram um equalização do histograma, além de ambas as imagens, *raw* e processadas, terem seu tamanho dividido por 4, de forma a otimizar o tempo computacional. Aproveitando-se da anatomia simétrica entre as mamas esquerda e direita, todas as imagens da mesma paciente foram refletidas, unindo assim os músculo peitorais.

Depois da padronização acima descrita, as imagens foram segmentadas retirando a área correspondente ao fundo, além da detecção da borda da mama. A borda entre o músculo peitoral e o tecido da mama foi feita usando algoritmo baseado na transformada de Hough. Com os mamogramas segmentados, foi utilizado o método de *clustering Fuzzy c-means* (FCM), que visa particionar uma quantidade finita de elementos dentre uma quantidade ‘*k*’ de *clusters* (grupos).

Assim, a ideia era particionar o tecido mamário em sub-regiões de intensidade de nível de cinza homogêneos. Dado que a distribuição global dos valores de intensidade de pixel em uma mamografia digital pode ser pensado como uma mistura de várias distribuições gaussianas diferentes, foi computado o ‘*k*’ adaptativo para cada imagem, baseado nas propriedades do histograma dentro da região da mama.

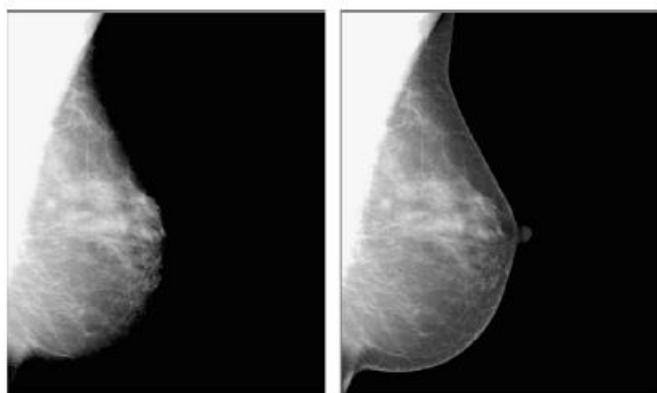
Para transformar a saída do algoritmo FCM em duas classes (gorduroso e denso), um classificador do tipo *Support Vector Machine* (SVM) é aplicado para determinar quais dos agrupamentos (*clusters*) de FCM são predominantemente densos para uma dada imagem mamográfica. O classificador SVM é executado de forma a minimizar o espaço de parâmetro e reduzir a probabilidade de *overfitting*. Mais especificamente, o SVM utiliza parâmetros de aquisição de imagem e características do paciente, que estão correlacionados com a PD%, tais como: a dose de raios X, a idade do paciente e a espessura da mama, a fim de dividir os *clusters*. Um conjunto de atributos de textura e descriptores de forma foram usados para classificar as imagens nas categorias do BI-RADS™.

A forte associação entre o algoritmo computadorizado e a estimativa feita visualmente pelos radiologistas provou a eficácia do método automático de estimativa de densidade mamária em imagens digitais. Para as imagens *raw data*, o coeficiente de correlação de Pearson (*r*) foi de 0,82 e para imagens processadas de 0,85. Além disso, foi possível

comprovar a versatilidade do método, visto que os resultados foram significativos em ambas as imagens.

Outro trabalho de Keller e colaboradores (KELLER *et al.*, 2013), no ano seguinte, objetivou determinar a variabilidade inerente a dois leitores de mamogramas na caracterização de imagens *raw* e processadas, segundo o padrão BI-RADS™ de densidade mamária. Foram usadas imagens de um banco próprio contendo 324 imagens digitais. A Figura 3.6 mostra um exemplo dessas imagens utilizadas nesse estudo.

Figura 3.6 – Imagens sob vista MLO da categoria II do BI-RADS™: (a) Imagem *raw*. (b) Imagem processada.



Fonte: (KELLER *et al.*, 2013).

Clinicamente, a densidade da mama é mais comumente estimada por radiologistas através de avaliação visual pela quantidade de tecido denso da mama, ou "áreas claras", e, então, categorizadas de acordo com os 4 padrões BI-RADS™. Além disso, medidas de percentual de densidade mamária (PD%), adquiridos utilizando "software de limiar interativo de imagem", também têm sido amplamente utilizado, principalmente no contexto de investigação, como um método mais preciso, para estimar melhor o risco de câncer de mama associado com o aumento da quantidade de tecido fibroglandular.

Recomenda-se que a densidade da mama deve ser avaliada usando as imagens "raw", porque elas mantêm uma relação proporcional entre a intensidade de tons de cinza da imagem e as propriedades dos tecidos adjacentes devido à atenuação de raios X. No entanto, a maioria das avaliações de densidade mamária realizadas por radiologistas são feitas principalmente em imagens processadas, porque estas são aquelas usadas para a interpretação clínica e arquivados pela maioria dos centros clínicos.

O cálculo da PD% foi feito a partir de um software interativo, sendo que a segmentação da mama foi feita manualmente. A PD% nada mais é do que a razão entre a área de tecido denso, sobre a área da mama. Toda a análise estatística foi feita a partir do MATrix LABoratory (MATLAB).

Os resultados indicaram que a variabilidade entre os leitores não foi afetada pelo tipo de imagem, *raw* ou processada, com estimativas de densidade mamária fortemente correlacionada entre os leitores. Algumas diferenças sistemáticas entre os 2 tipos de imagem observados, apesar de pequenas, foram detectadas. Em um caso particular, o percentual de densidade (PD%), foi menor na imagem processada em comparação com a imagem “*raw*”. Em contraste, a estimativa do segundo leitor quanto a área absoluta da mama foi significativamente maior em comparação com a imagem “*raw*”.

Os resultados mostraram também que a densidade mamográfica pode ser avaliada com a mesma confiabilidade, tanto na imagem “*raw*” quanto na processada. Além disso, os resultados sugerem que a principal fonte de variabilidade da densidade vem da subjetividade do leitor individual na avaliação da quantidade absoluta de tecido denso na mama, indicando a necessidade de utilizar ferramentas padronizadas para atenuar este efeito.

Fowler e colaboradores (FOWLER *et al.*, 2014) propuseram um método automático para a medida de densidade mamária, assim como o software VolparaTM, entretanto diferenciando-se pelo fato de que neste método proposto as imagens analisadas foram associadas com o risco de câncer de mama. Os resultados mostraram que o cálculo automático da porcentagem de densidade mamária foram semelhantes para as imagens *raw* e processadas.

Um novo esquema de classificação de densidade mamária foi proposto por Vállez e pesquisadores (VÁLLEZ *et al.*, 2014). Sabe-se que a interpretação da imagem é dificultada quanto maior for a predominância de tecido denso da mama. Dessa forma, classificadores automáticos de imagens por densidade mamária pode ajudar a detecção de lesão e a análise do exame. Vários métodos de classificação foram comparados e um novo procedimento de classificação hierárquica de classificadores combinados com análise discriminante linear (LDA) foi proposta como a melhor solução para classificar as mamografias dentre as quatro categorias BI-RADSTM.

Os resultados obtidos para 322 imagens de filme do banco mini-MIAS mostraram que 99,75% das amostras foram corretamente classificadas. Para 1137 mamogramas (FFDM), a taxa de acerto obtida foi de 91,52%.

No estudo mais recente de Angulo e colaboradores (ANGULO *et al.*, 2015) foi aplicado PCA sobre um banco de imagens digitais de treinamento, de forma a criar quatro diferentes grupos, um para cada categoria BI-RADS™ de composição mamária. O *score* foi obtido projetando o histograma da imagem a ser classificada dentro dos quatro grupos criados, atribuindo-o à classe mais próxima.

De forma a validar o algoritmo, um conjunto de 86 imagens foram divididas para treino, e outro banco de 964 imagens foram separadas para teste. Todos os mamogramas foram obtidos sob vista CC e sem nenhuma patologia visível. Oito radiologistas experientes categorizaram as imagens mamográficas de acordo com o padrão BI-RADS™, e suas avaliações consideradas como padrão ouro.

A partir dos resultados comprovou que a melhor concordância entre o algoritmo proposto e o padrão ouro ocorreu para o grupo de imagens de treino, com índice kappa igual a 0,74. Para o conjunto teste, o índice kappa obtido foi de 0,44, o que sugeriu que o método pode ser usado para a classificação BI-RADS™ de densidade mamária, mas é necessário um melhor treinamento.

Na Tabela 3.2 é apresentando um resumo da maioria dos trabalhos descritos neste Capítulo, de forma a facilitar a comparação e análise dos diversos métodos utilizados. Vale ressaltar que o banco de imagens Nijmegen, Oxford, mini-MIAS são provenientes de mamografias em filme.

Tabela 3.2 – Comparação de métodos de classificação de densidade mamária encontrados na literatura (k-NN: vizinhos mais próximos, RBH: *rule-based histogram*, RNA: Rede Neural Artificial, ID3: árvore de decisão, SVM: máquina de vetor de suporte, LBN: *linear Bayes normal*, VT: *voting tree*).

| Trabalho | Atributos | Imagens | Tipos de tecidos | Segmentação | Classificador e taxa de acerto |
|---|----------------------|-----------------|------------------|-------------|--------------------------------|
| Karssemeijer, 1998 | Histograma | 615 - Nijmegen | 4 | Sim | k-NN – 66% |
| Zhou <i>et al.</i>, 2001 | Histograma | 260 - filme | 4 | Sim | RBH – 92,5% |
| Bovis, Singh, 2002 | Textura e frequência | 377 - filme | 2 | Não | RNA – 96,7% |
| | | | 4 | Não | RNA – 71,4% |
| Petroudi, Kadir, Brady, 2003 | Textura | 132 - Oxford | 4 | Sim | k-means – 75% |
| Wang <i>et al.</i>, 2003 | Histograma | 195 - Filme | 4 | Não | RNA – 71% |
| Oliver, Freixenet, Zwiggelar, 2005 | Textura e morfologia | 300 - DDSM | 4 | Sim | k-NN – 67% |
| | | | | Sim | ID3 – 73% |
| Bosch <i>et al.</i>, 2006 | Textons | mini-MIAS | 3 | Sim | SVM – 91,39% |
| | | DDSM | 4 | Sim | SVM – 84,75% |
| Castella <i>et al.</i>, 2007 | Textura | 352 - filme | 4 | Não | LBN – 76% |
| Boehm <i>et al.</i>, 2008 | Textura | 100 – filme | 3 | Não | Teste T – 89% |
| Oliver <i>et al.</i>, 2008 | Textura e morfologia | 322 – mini-MIAS | 4 | Sim | LBN – 79,25% |
| Subashini, Ramalingam, Palanivel, 2010 | Textura | 43 - MIAS | 3 | Sim | SVM – 95,44% |
| Cheng <i>et al.</i>, 2010 | Textons | 23 – filme | 4 | Não | SVM – 80,7% |
| Wang <i>et al.</i>, 2011 | Textons iterativos | 322 – mini-MIAS | 3 | Sim | SVM – 89% |
| Tzikopoulos <i>et al.</i>, 2011 | Fractais | 322 – mini-MIAS | 3 | Sim | SVM – 85,7% |
| Liu <i>et al.</i>, 2011 | Momentos | 88 FFDM | 4 | Sim | SVM – 86,4% |
| Mustra, Grgic, Delac, 2012 | Textura | MIAS | 3 | Sim | k-NN – 82,5% |
| | | Digital | 4 | | k-NN – 76,4% |
| Tortajada <i>et al.</i>, 2012 | Textura e morfologia | 236 FFDM | 4 | Sim | LBN – 92% |
| Vállez <i>et al.</i>, 2014 | Textura | mini-MIAS | 4 | Não | VT – 99,75% |
| | | FFDM | 4 | Não | VT – 91,52% |

Capítulo 4 ANÁLISE E CLASSIFICAÇÃO DE IMAGENS

O reconhecimento de padrões vem sendo amplamente utilizado em estudos relacionados à área médica, voltado principalmente à sistemas de auxílio ao diagnóstico. Ele é usado no âmbito de imagens médicas, especialmente na caracterização de tumores, quantificação de deformidades de estruturas anatômicas e visualização de contornos.

Esta área do conhecimento tem como objetivo desenvolver técnicas e métodos para analisar as características, também chamados de atributos, de um determinado objeto, podendo assim categorizá-lo em uma determinada classe, grupo ou conjunto que este objeto em questão pertence, denominado classificação. O objeto em estudo, no caso, imagens mamográficas devem então passar por etapas de processamento que consistem na extração de atributos, seleção e por fim na classificação das imagens em determinados grupos, dependendo do método proposto.

Neste Capítulo serão abordados os temas referentes às etapas de processamento de imagens digitais, sobretudo ao processo de extração e seleção de atributos, além das técnicas implementadas para a classificação das imagens.

4.1 Extração de atributos

A extração dos atributos de um conjunto de imagens pode evidenciar suas similaridades e diferenças. Algoritmos de extração de atributos são definidos como métodos que aplicam transformações lineares ou não lineares sobre as características originais da imagem, gerando assim novos atributos (PRATT, 1991; HUBER, DUTRA, 1998). O principal objetivo desta etapa é caracterizar os objetos através de medidas, para serem utilizados na classificação de imagens (DUDA, HART, STORK, 2012).

O estudo de extração de atributos em reconhecimento de padrões requer a definição de dois elementos (PANDYA, MACY, 1995):

- Atributos: são as características de um objeto, podendo ser simbólicos, numéricos ou ambos;
- Padrão: é um conjunto de atributos que definem um objeto ou um grupo de objetos, formando assim uma mesma classe ou categoria.

Para imagens mamográficas, no caso da extração de atributos de microcalcificações e também de nódulos, é preciso obter informações que possibilitem a identificação da malignidade ou não (ou ainda quantificar a suspeita). Por isso, atributos geométricos são relevantes, uma vez que as medidas de área, perímetro, compacidade, irregularidade, momentos, entre outras, são significativas para associação das estruturas entre lesões malignas ou benignas.

Como neste trabalho a classificação se dará em termos de composição mamária, atributos geométricos não são tão relevantes, visto que a diferenciação entre os tecidos é mais nítida em nível de intensidade de pixels e de textura. Desta forma, foram então extraídos das imagens atributos de intensidade baseados em histograma e descriptores de textura, explicados a seguir.

4.1.1 Atributos extraídos do histograma

O histograma é a forma mais útil e mais frequente de representar os tons de cinza, também conhecidos como *digital numbers* (DN), de uma determinada imagem. Ele fornece a informação sobre a frequência de pixels da imagem que possuem um certo valor de DN, variando de 0 a 255 em imagens de 8 bits, por exemplo, e variando de 0 a 4095 em imagens de 12 bits (GONZALEZ, WOODS, 2010).

O histograma nada mais é do que uma distribuição de intensidade, representado por um gráfico em barras que fornece para cada nível de cinza o número de pixels correspondentes a esta cor presente na imagem. A partir da análise de um histograma, é possível se ter uma ideia da imagem em termos de brilho e contraste ((MARQUES FILHO, VIEIRA NETO, 1999). Por exemplo, um histograma bimodal sugere que uma imagem contém um objeto com amplitude maior que seu fundo e pode sugerir o grau de contraste, já um histograma no qual os pixels estão concentrados em uma faixa pequena de valores indica uma imagem de baixo contraste (PRATT, 2001).

Neste trabalho, os atributos extraídos do histograma utilizados são apresentados a seguir:

1. Média de níveis de cinza do histograma: corresponde à soma de todos os valores de intensidade de pixel da imagem dividido pelo número total de pixels da imagem;
2. Valor de intensidade do maior pico do histograma: corresponde ao valor de intensidade de pixel com maior frequência no histograma (moda);

3. Valor de menor intensidade do histograma: menor valor de intensidade de pixel encontrado no histograma;
4. Valor de maior intensidade do histograma: maior valor de intensidade de pixel encontrado no histograma;
5. Diferença da média para o menor valor: valor obtido em (1) subtraído de (3);
6. Diferença da média para o maior valor: módulo da subtração de (1) por (4);
7. Porcentagem da maior intensidade em relação à intensidade máxima possível: maior valor de intensidade de pixel encontrado no histograma dividido pela intensidade máxima possível (dependente da resolução da imagem – 8 bit \rightarrow 255), multiplicado por 100 para obter-se a porcentagem;
8. Número de pixels maior que o pico do histograma: quantidade de pixels com intensidades acima daquela calculada em (2);
9. Gradiente de pixels: valor calculado em (4) subtraído de (3).

4.1.2 Atributos de textura

A textura é definida como uma combinação entre magnitude e frequência da variação de tons em uma imagem. Apesar da intensidade de níveis de cinza e a textura serem independentes, uma está intrinsecamente ligada à outra, isto é, quando uma pequena área de uma imagem tem muita variação de níveis de cinza, a propriedade dominante é a textura (HARALICK, SHANMUGAM, DINSTEIN, 1973; HARALICK, 1979).

A textura pode ser caracterizada por três componentes: contraste local, orientação e escala. O primeiro é a diferença de níveis de cinza entre áreas vizinhas mais claras e mais escuras. Imagens com áreas de alto contraste local possuem textura rugosa, já o contrário, isto é, baixo contraste local, significa textura mais lisa. A orientação está relacionada à disposição da direção dessas áreas mais claras ou mais escuras. Já a escala pode ser definida como a dimensão das áreas de uma imagem, resultando em texturas finas e grossas, dependentes destas dos tamanhos das áreas claras ou escuras (RUBIN, 1989).

Segundo Gonzalez e Woods (GONZALEZ, WOODS, 2010), a textura possui três abordagens principais em processamento de imagens, sendo elas:

- Abordagem espectral: baseadas em propriedades do espectro de Fourier, utilizadas principalmente na detecção de periodicidade global, identificando picos de alta energia no espectro;

- Abordagem estatística: neste caso a textura é definida por um conjunto de medidas locais extraídas do padrão;
- Abordagem estrutural: baseada na ideia de que as texturas são compostas de primitivas dispostas de forma regular e repetitiva.

Neste trabalho optou-se pela abordagem estatística, extraíndo os 14 descritores de textura de Haralick (HARALICK, SHANMUGAM, DINSTEIN, 1973) a partir da matriz de coocorrência de níveis de cinza (SGLD – *Spatial Gray-Level Dependence*), calculando a probabilidade de ocorrência combinada de direção e distância entre pares de pixels com valores de intensidade semelhantes. A matriz de coocorrência SGLD é uma matriz quadrada de tamanho igual à quantidade de níveis de cinza da imagem a ser analisada.

O conjunto dos 14 descritores de Haralick extraídos no trabalho são apresentados e explicados a seguir. Vale destacar que, n corresponde à quantidade de níveis de cinza da imagem, e $P(i,j)$ a matriz de coocorrência dos níveis de cinza.

1. Uniformidade ou Energia: indica invariabilidade, homogeneidade. Texturas homogêneas terão valor de uniformidade ou energia mais alto, pois as texturas suaves possuem densidades mais concentradas;

$$\text{Uniformidade} = \sum_i \sum_j P(i, j)_{\Delta x, \Delta y}^2 \quad (4.1)$$

2. Contraste: estimativa da variação de intensidade entre pares de pixels da imagem. Quanto menor o contraste, menor será essa medida, e texturas de alto contraste o valor para esse descritor será maior;

$$\text{Contraste} = \sum_i \sum_j (i - j)^2 P(i, j)_{\Delta x, \Delta y} \quad (4.2)$$

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

$$\text{Correlação} = \frac{\sum_i \sum_j ij P(i, j)_{\Delta x, \Delta y} - \mu_l \mu_c}{\sigma_l \sigma_c} \quad (4.3)$$

4. Variância: indica a variação de intensidade do fundo da imagem;

$$\text{Variância} = \sum_i \sum_j \frac{P(i, j)_{\Delta x, \Delta y}}{1 + (i - j)^2} \quad (4.4)$$

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

$$\text{Momento da diferença inversa} = \sum_k k P^D(k)_{\Delta x, \Delta y} \quad (4.5)$$

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

$$\text{Média da soma} = \sum_k k P^S(k)_{\Delta x, \Delta y} \quad (4.6)$$

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

$$\text{Variância da soma} = \sum_k (k - \text{MS}_{\Delta x, \Delta y})^2 P^S(k)_{\Delta x, \Delta y} \quad (4.7)$$

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

$$\text{Entropia da soma} = - \sum_k P^S(k)_{\Delta x, \Delta y} \log P^S(k)_{\Delta x, \Delta y} \quad (4.8)$$

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

$$\text{Entropia} = - \sum_i \sum_j P(i, j)_{\Delta x, \Delta y} \log P(i, j)_{\Delta x, \Delta y} \quad (4.9)$$

10. Variância da diferença: variância calculada com a média centrada em zero, no qual MD é igual a média da diferença inversa;

$$\text{Variância da diferença} = \sum_k (k - \text{MD}_{\Delta x, \Delta y})^2 P^D(k)_{\Delta x, \Delta y} \quad (4.10)$$

11. Entropia da diferença: indica a desorganização entre os pixels de um fundo;

$$\text{Entropia da diferença} = - \sum_k P^D(k)_{\Delta x, \Delta y} \log P^D(k)_{\Delta x, \Delta y} \quad (4.11)$$

12. Medida de Informação de Correlação 1: indica a correlação baseada na medida da entropia de elementos independentes e pares de elementos da imagem;

$$\text{Medida de informação de correlação 1} = \sum_k P^D(k)^2_{\Delta x, \Delta y} \quad (4.12)$$

13. Medida de Informação de Correlação 2: similar à Medida de Informação de Correlação 1, entretanto o cálculo é feito com base na similaridade entre as entropias.

$$\text{Medida de Informação de correlação 2} = \sum_k P^S(k)^2_{\Delta x, \Delta y} \quad (4.13)$$

14. Máximo coeficiente de correlação: é um indicador da heterogeneidade da distribuição de níveis de cinza.

$$\text{Máximo coeficiente de correlação} = \sum_i \sum_j \frac{P(i, j)^2_{\Delta x, \Delta y}}{P(i, *)_{\Delta x, \Delta y} P(*, j)_{\Delta x, \Delta y}} \quad (4.14)$$

Após essa extração de atributos, é preciso selecionar quais destes são mais significantes, permitindo assim separar padrões em classes. Tendo em vista esses padrões já determinados, utiliza-se de técnicas de classificação para que cada imagem seja separada de acordo com a sua classe.

4.2 Seleção de atributos

A seleção de atributos é a etapa posterior à extração das características do objeto em análise. O processo de seleção de atributos tem como função mapear as medidas extraídas dos padrões (imagens) em características significativas (GONZALEZ, WINTZ, 1992; MASCARENHAS, VELASCO 1989).

A principal finalidade da seleção de atributos é a redução da dimensão dos dados. Isto significa dizer que os métodos de seleção de atributos produzem um conjunto reduzido de dados a serem analisados. As grandes vantagens desta redução de variáveis são: remoção de características irrelevantes ou redundantes, a visualização gráfica do novo conjunto de atributos e produzir uma representação mais estável, melhorando o desempenho do classificador.

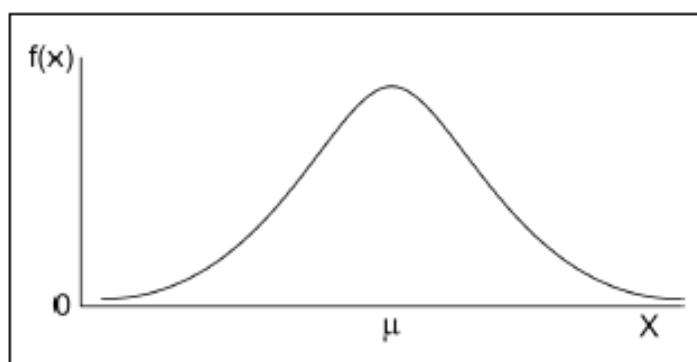
Basicamente, manter a dimensionalidade dos dados a menor possível é importante principalmente devido ao menor custo computacional (menor uso de memória e classificador mais rápido) e a maior acurácia do classificador. Entretanto, em alguns casos, uma redução muito brusca do número de atributos analisados pode reduzir o desempenho do classificador, em virtude de uma perda na capacidade de discriminação dos dados.

Existem vários métodos de seleção de atributos, sendo que o método adequado é escolhido de acordo com a natureza do problema. Os dados basicamente possuem dois tipos de distribuição: normal ou anormal (distribuição livre).

A distribuição normal ou gaussiana pode ser utilizada como método de seleção de atributos, sendo construída com base nos valores de média (μ) e desvio padrão (σ) dos dados normalizados (Figura 4.1). Para todas as classes de atributos analisadas, é gerada uma curva gaussiana referente à distribuição dos valores.

Quanto menor a sobreposição (intersecção) das curvas, melhor aquele atributo representará aquela classe singularmente. Além da intersecção das curvas, também se analisa o eixo das abscissas, que representa a faixa de distribuição de valores de cada classe para um mesmo atributo. Assim é possível evitar selecionar atributos de uma mesma faixa de valores, isto é, atributos que poderiam ser ambíguos e que causariam confusão no método de classificação proposto.

Figura 4.1 – Distribuição normal (Gaussiana).



Para que os dados sejam utilizados em uma distribuição normal, é preciso que eles estejam ou sejam normalizados. O objetivo da normalização é minimizar os problemas oriundos do uso de unidades e dispersões distintas entre as variáveis. Uma das técnicas de normalização é conhecida como normalização mín-máx, dado pela Equação 4.15 abaixo. Nesta técnica é utilizado os valor mínimo (\min_D) e máximo (\max_D) dos dados analisados,

além do valor (v) que será normalizado, gerando assim um novo valor (v') normalizado entre o intervalo [0-1].

$$v' = \frac{v - \min_D}{\max_D - \min_D} \quad (4.15)$$

4.3 Classificação de imagens

Durante a etapa de análise e processamento dos dados, a classificação consiste na separação do objeto de estudo em classes. O problema da classificação está na construção de um processo que será aplicado em uma sequência de casos, sendo que cada novo caso deve ser associado a um conjunto de classes pré-definidas, com base nos atributos extraídos.

As técnicas de classificação podem ser do tipo não supervisionada ou supervisionada. Para a construção de um procedimento de classificação para um conjunto de dados em classes, nas quais as verdadeiras não são bem conhecidas, pode-se definir o chamado de aprendizagem não supervisionada e "clusterização" (agrupamento de dados por semelhança de atributos) (TROSSET, 2001). Neste trabalho a técnica de *clustering k-means* foi utilizada e será explicada posteriormente.

Já em uma técnica de classificação supervisionada, o resultado é conhecido, isto é, o método foi treinado anteriormente, sendo assim há um agente externo que indica para o classificador a saída desejada. Neste trabalho foi proposto uma Rede Neural Artificial com treinamento supervisionado, explicada posteriormente no item 4.3.2.

A escolha do classificador, ou de sua arquitetura, é um dos pontos chave para o desenvolvimento de uma aplicação. O tipo de classificador e sua arquitetura é que podem distinguir características normais e anormais de um padrão. Isso tem mostrado que a performance de um classificador para casos não conhecidos previamente depende também do conjunto de exemplos usados para seu treinamento e teste (FUKUNAGA, 1990).

A questão enfatizada nesse trabalho é a classificação de imagens mamográficas em classes de densidade mamária.

4.3.1 Técnica de agrupamento *k-means*

O método de agrupamento mais conhecido e simples, baseado na distância, foi proposto por Forgey (FORGEY, 1965) e é denominado *k-means*. Esse método objetiva partitionar ‘n’ observações dentre ‘k’ *clusters* (grupos, classes) estabelecidos previamente, no qual cada observação pertence ao cluster mais próximo de sua média. A ideia básica é a de escolher e atualizar os centroides dos ‘k’ *clusters*, um para cada grupo a ser detectado (BOUKERROUI *et al.*, 1998).

O *k-means* é uma heurística de agrupamento não hierárquico que busca minimizar a distância dos elementos a um conjunto de ‘k’ centros dado por $\chi=\{x_1, x_2, \dots, x_k\}$ de forma iterativa. A distância entre um ponto p_i e um conjunto de *clusters*, dada por $d(p_i, \chi)$, é definida como sendo a distância do ponto ao centro mais próximo dele, visando minimizar o erro quadrático médio entre as amostras e sua classe (HARTIGAN, WONG, 1979).

O método *k-means* pode ser resumido pelas seguintes etapas:

- 1) Obter os *k* pontos dos protótipos iniciais e armazená-los numa lista *W*;
- 2) Calcular todas as distâncias entre cada protótipo p_i (ou média) e cada vetor de atributos, produzindo-se uma matriz de distâncias *D* de $K \times N$;
- 3) Usar a Matriz *D* para identificar os atributos que são próximos de cada P_i (isso pode ser feito encontrando os mínimos valores em cada coluna de *D*);
- 4) Armazenar os pontos dentro da respectiva lista L_i ;
- 5) Obter como novos protótipos os centroides das características armazenadas dentro de cada L_i respectiva.

Os passos de 2 a 5 devem ser repetidos até que se estabilize o número de centroides de classes. A fórmula da técnica de *k-means* é mostrada na Equação 4.16.

$$K = \sum_{j=1}^k \sum_{i=1}^n \|x^{(j)} - c_j\|^2 \quad (4.16)$$

Na equação, $\|x^{(j)} - c_j\|^2$ representa a medida de distância definida na implementação do algoritmo *k-means*, sendo ‘x’ a variável analisada, ‘c’ o *cluster* conhecido.

4.3.2 Redes Neurais Artificiais

Redes Neurais Artificiais (RNA) são modelos simplificados do sistema nervoso central. Elas são redes de elementos computacionais neurais altamente interconectados que possuem a habilidade de responder a um estímulo de entrada e de aprender a se adaptar dentro de um ambiente.

Inicialmente o estudo de redes neurais foi motivado pela capacidade fantástica do cérebro humano em executar tarefas altamente complexas, não lineares e com processamento paralelo da informação. Esses fatos geraram o interesse em um estudo mais aprofundado da constituição do cérebro e na tentativa de mimetização na concepção de sistemas com as capacidades acima referidas, designadas por Redes Neurais Artificiais - RNA (BEALE, JACKSON, 1990).

Este tipo de rede tem se mostrado um processamento computacional bem efetivo para várias tarefas, tais como: reconhecimento de padrões, classificação, compressão de dados, modelagem e previsões, resolução de problemas combinatórios, controle adaptativo, filtragem de ruídos, entre outros. Elas possuem um vasto número de propriedades desejáveis, não encontradas em sistemas computacionais convencionais, como: desempenho robusto lidando com ruído ou padrões de entrada incompletos, alto grau de tolerância a falhas, altas taxas de processamento computacional paralelo, a habilidade de generalização, aprendizagem adaptativa, flexibilidade e auto-organização (KOVÁCS, 2002).

Apesar das diversas Redes Neurais Artificiais se diferirem entre si em várias características, um típico neurônio ou elemento computacional da RNA é basicamente um comparador que produz uma saída quando o efeito acumulativo do estímulo de entrada excede o valor limiar (*threshold*).

A modelagem de uma rede envolve: neurônio, arquitetura e algoritmo de aprendizagem. Os neurônios, também chamados de nós ou unidades de processamento, estabelecem a unidade computacional básica da rede e podem ser unidades de entrada, recebendo entradas de fontes externas. São elementos processadores interligados, que trabalham em paralelo para desempenhar uma determinada tarefa.

A operação feita pelo neurônio (unidade de processamento) pode ser resumida da seguinte forma:

- Sinais chegam à entrada;

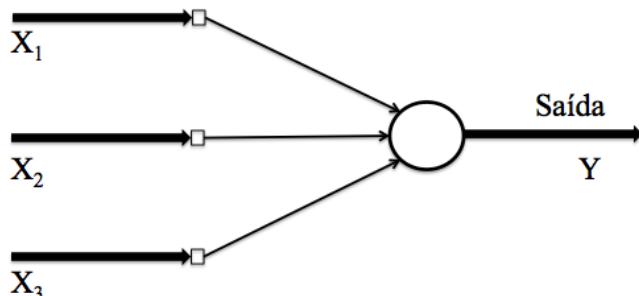
- Cada sinal é multiplicado por um número (peso) que indica a sua influência na saída da unidade;
- É feita a soma ponderada dos sinais que produz um nível de atividade;
- Se este nível de atividade exceder um certo limite (*threshold*), a unidade produz uma determinada resposta de saída.

Já a arquitetura, ou topologia da rede, determina a estrutura das conexões entre os neurônios, podendo ser intra-camadas (ocorrem entre neurônios da mesma camada), inter-camadas (ocorre entre neurônios de camadas diferentes) e recorrente (a conexão parte e chega do mesmo neurônio). O algoritmo de aprendizagem estabelece o método pelo qual o estado individual e suas conexões serão alterados, para que a rede atinja um comportamento global (MASTERS, 1994).

Na Figura 4.2 abaixo, um simples neurônio da rede é ilustrado, com três entradas e apenas uma saída.

Figura 4.2 – Modelo simples de uma Rede Neural Artificial.

Entradas



Cada ligação de entrada ($i=1,2,3$) tem um sinal externo de entrada associado ou um estímulo e um peso correspondente. Os valores de entrada podem ser reais (+ ou -), binários (0 ou 1), ou bipolares (-1,+1). Os pesos atuam no sentido de aumentar (estímulo excitatório) ou diminuir (estímulo inibitório) o sinal de entrada para o neurônio. Os pesos podem também ser valores reais, binários ou bipolares. Algumas redes apresentam um sinal adicional *bias*, favorecendo ou limitando a possibilidade de ativação do neurônio.

O neurônio se comporta como um ativador ou função de mapeamento, produzindo uma saída $y=f(net)$, no qual a rede (*net*) executa o somatório dos sinais produzidos gerados do produto dos sinais de entrada pelo peso. Já ‘*f*’ é dada como a função de ativação da rede, comumente podendo ser:

- **Linear:** O fator de amplificação dentro da região de operação é assumido unitário e é apresentada pela equação:

$$F(Net_k) = \begin{cases} 1 & \text{Se } 0,5 \leq Net_k \\ Net_k & \text{Se } -0,5 < Net_k < 0,5 \\ 0 & \text{Se } Net_k < -0,5 \end{cases}$$

- **Degrau:** esta função modela a característica de “tudo ou nada” do neurônio, definida pela equação:

$$F(Net_k) = \begin{cases} 1 & \text{Se } Net_k \geq 0 \\ 0 & \text{Se } Net_k < 0 \end{cases}$$

- **Logsig:** função estritamente crescente que apresenta um equilíbrio entre o desempenho linear e não linear, sendo expressa pela equação:

$F(Net_k) = \frac{1}{1 + e^{-a \cdot Net_k}}$, no qual ‘a’ é o coeficiente de inclinação e ‘net_k’ é o valor de ativação do neurônio.

- **Tansig:** possui a forma sigmoidal e diferencia-se da função logsig pelo fato de poder assumir valores na faixa de [-1, 1]. A equação deste tipo de função é:

$$F(Net_k) = \frac{2}{1 + e^{-a \cdot Net_k}} - 1$$

A capacidade de aprendizado pelo próprio ambiente é característica marcante das Redes Neurais, o que permite uma melhoria significativa no seu desempenho. O treinamento da rede nada mais é do que um processo iterativo de ajustes que são aplicados aos pesos. O aprendizado ocorre quando a RNA atinge uma solução generalizada para um problema. Denomina-se algoritmo de aprendizado um conjunto de regras bem definidas que visam solucionar um eventual problema que venha a surgir no aprendizado da rede.

Por isso, é importante a maneira pela qual uma rede neural se relaciona com o ambiente, podendo ser supervisionada e não supervisionada.

Em um aprendizado supervisionado, a RNA é treinada com auxílio de um supervisor, também chamado de “professor”. Para que isso aconteça, a rede deverá conter pares de entrada e saída, ou seja, um conjunto de entradas e seu respectivo conjunto de saídas desejadas para cada entrada. Toda vez que for apresentada à rede uma entrada, deverá ser verificado se a saída gerada (com base nos cálculos efetuados a partir dos pesos que a rede possui) confere com a saída desejada para aquela entrada. Caso seja diferente, a rede deverá ajustar os pesos de forma que armazene o conhecimento desejado. Esta interatividade do treino deverá ser repetida com todo conjunto de treinamento (entradas e saídas), até que a taxa de acerto esteja dentro de uma faixa considerada satisfatória (MASTERS, 1994; PATTERSON, 1995).

Já no aprendizado não supervisionado, os vetores de entrada não são associados com a saída desejada no processo de treinamento, ou seja, não há a presença de supervisores, sendo que o próprio modelo extrai propriedades estatísticas do conjunto de treinamento, possibilitando se auto-organizar, como nos modelos de Konohen e no modelo ART (*Adaptative Ressonance Theory*) (HERTZ, KROGH, PALMER, 1991).

4.3.3 Algoritmo *Backpropagation*

Herbert Robbins e Sutton Monro (ROBBINS, MONRO, 1951) propuseram da década de 50 uma ferramenta estatística denominada método de aproximação estocástica no qual é baseado o algoritmo *backpropagation* (BP). Esta técnica tem obtido êxito em reconhecimento de padrões e sistemas de identificação. O algoritmo BP tornou-se popular com os trabalhos de Rumelhart, Hinton e Williams em 1986 (RUMELHART, HINTON, WILLIAMS, 1986).

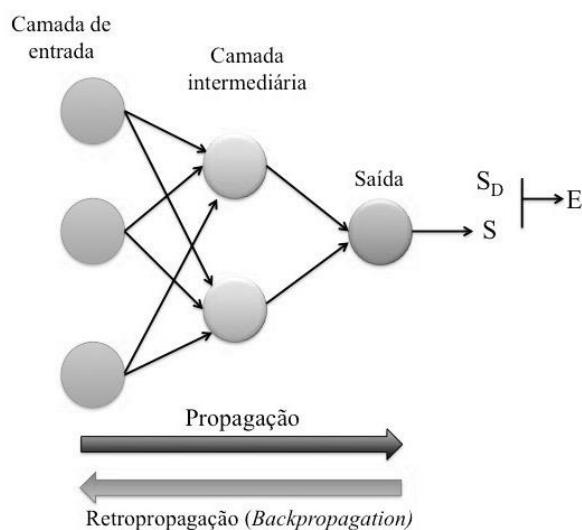
O algoritmo BP busca, de maneira iterativa, achar a mínima diferença entre as saídas desejadas e as saídas obtidas pela rede neural, com o menor número possível de erros. Assim calcula-se o erro para a camada de saída e propaga-se o mesmo no sentido inverso (saída → entrada). Os pesos então são ajustados entre as camadas através da retropropagação em cada iteração (HAYKIN, 1994; (RUMELHART, HINTON, WILLIAMS, 1986)

Como este tipo de algoritmo pertence a um aprendizado supervisionado, a rede é analisada em dois casos: no sentido ‘entrada → saída’, propagação, e principalmente no sentido ‘saída → entrada’, retropropagação. No primeiro, os pesos sinápticos da rede são todos fixos, enquanto que no segundo, os pesos vão sendo ajustados como funções dos erros calculados.

Em resumo, um padrão de entrada é aplicado com um estímulo aos elementos da camada inicial da rede que é então propagado pelas demais camadas, até que seja gerada uma saída (S). Essa saída é comparada com a saída desejada (S_D), gerando um sinal de erro (E) para cada elemento da saída. Por fim, o sinal de erro é retropropagado da camada de saída para cada elemento da camada anterior.

Porém, cada elemento da camada escondida (intermediária) não recebe o sinal de erro total, e sim apenas uma parte, aquela proporcional à colaboração relativa de cada elemento na formação da saída original. A cada iteração, o processo vai se repetindo, de maneira que cada elemento da RNA recebe um sinal de erro que relate a sua contribuição para o erro total, e assim os pesos vão sendo atualizados e ajustados. A Figura 4.3 abaixo mostra um esquema do algoritmo *backpropagation*.

Figura 4.3 – Esquema simples de uma rede *feedforward* com algoritmo *backpropagation*.



Seguindo o algoritmo *backpropagation* tradicional e considerando-se as variáveis seguintes, têm-se (HERTZ, KROGH, PALMER, 1991)

w_{ij} = pesos das conexões da camada intermediária para camada de saída;

w_{jk} = pesos das conexões da camada intermediária j para camada de entrada k .

ξ_k^μ = entradas;

ξ_i^μ = saídas desejadas;

O_i = saídas obtidas pela rede;

V_j = valores das saídas dos neurônios da camada intermediária j .

As entradas são introduzidas à rede com um valor particular, sendo referenciadas por μ . O índice k refere-se a uma unidade de entrada, o índice j a uma unidade intermediária (ou da camada escondida) e por fim, o índice i sempre a uma unidade de saída. Usa-se N para o número de unidades de entrada e p para número de padrões de entradas ($\mu = 1, 2, \dots, p$).

Dado um padrão de entrada μ , as unidades j da camada escondida recebem uma entrada da rede:

$$h_j^\mu = \sum_k w_{jk} \xi_k^\mu \quad (4.17)$$

As saídas são processadas:

$$V_j^\mu = g(h_j^\mu) = g(\sum_k w_{jk} \xi_k^\mu) \quad (4.18)$$

no qual V_j^μ é a saída dos neurônios da camada intermediária e g é a função de ativação da rede.

As saídas da unidade i recebem:

$$h_i^\mu = \sum_j W_{ij} V_j^\mu = \sum_j W_{ij} g(\sum_k w_{jk} \xi_k^\mu) \quad (4.19)$$

no qual W_{ij} são os pesos das conexões dos neurônios da camada intermediária para os neurônios da camada.

As saídas da rede são processadas (O_i), sendo então as chamadas saídas obtidas pela rede:

$$O_i^\mu = g(h_i^\mu) = g(\sum_j W_{ij} V_j^\mu) = g(\sum_j W_{ij} g(\sum_k w_{jk} \xi_k^\mu)) \quad (4.20)$$

A função custo ou erro dada por:

$$E[w] = 1/2 \sum_{\mu i} [\zeta_i^\mu - O_i^\mu]^2 \quad (4.21)$$

torna-se

$$E[w] = 1/2 [\zeta_i^\mu - g(\sum_j W_{ij} g(\sum_k w_{jk} \xi_k^\mu))]^2 \quad (4.22)$$

A regra de atualização é local.

Considerando:

η = taxa de aprendizagem;

δ = erro;

Para calcular as saídas das camadas escondidas tem-se:

$$\begin{aligned}\Delta W_{ij} &= -\eta(\partial E / \partial W_{ij}) = \eta \sum_{\mu} [\zeta_i^{\mu} - O_i^{\mu}] g'(\mathbf{h}_i^{\mu}) V_j^{\mu} = \\ &= \eta \sum_{\mu} \delta_i^{\mu} V_j^{\mu}\end{aligned}\quad (4.23)$$

onde δ_i^{μ} é definido por:

$$\delta_i^{\mu} = g'(\mathbf{h}_i^{\mu}) [\zeta_i^{\mu} - O_i^{\mu}] \quad (4.24)$$

$$\begin{aligned}\Delta w_{jk} &= -\eta(\partial E / \partial w_{jk}) = -\eta \sum_{\mu} (\partial E / \partial V_j^{\mu}) (\partial V_j^{\mu} / \partial w_{jk}) \\ &= \eta \sum_{\mu i} [\zeta_i^{\mu} - O_i^{\mu}] g'(\mathbf{h}_i^{\mu}) W_{ij} g'(\mathbf{h}_j^{\mu}) \xi_k^{\mu} \\ &= \eta \sum_{\mu i} \delta_i^{\mu} W_{ij} g'(\mathbf{h}_j^{\mu}) \xi_k^{\mu} \\ &= \eta \sum_{\mu} \delta_j^{\mu} \xi_k^{\mu}\end{aligned}\quad (4.25)$$

$$\text{com } \delta_j^{\mu} = g'(\mathbf{h}_j^{\mu}) \sum_i W_{ij} \delta_i^{\mu}. \quad (4.26)$$

Este é o método de atualização dos pesos para redes de múltiplas camadas, conhecido como Gradiente Descendente.

O método do gradiente descendente é uma técnica de otimização usada para minimizar a dimensão dos erros. Ela pode ser generalizada da seguinte forma:

$$\Delta W_{pq} = \eta \sum_{\text{padrões}} \delta_{\text{saídas}} x V_{\text{entradas}} \quad (4.27)$$

onde p e q são as conexões entre duas camadas e V as entradas e/ou saídas processadas nas camadas intermediárias (ou escondidas).

Capítulo 5 METODOLOGIA

Este Capítulo trata da metodologia utilizada durante a execução do trabalho, explicando toda a etapa de processamento das imagens, partindo dos bancos de imagens utilizados, da extração e seleção de atributos, até a classificação das imagens dentro das classes de densidade mamária.

Em um primeiro momento, os testes iniciais foram feitos com imagens digitalizadas em filme, e posteriormente, a classificação das imagens foi feita utilizando um banco de imagens digitais.

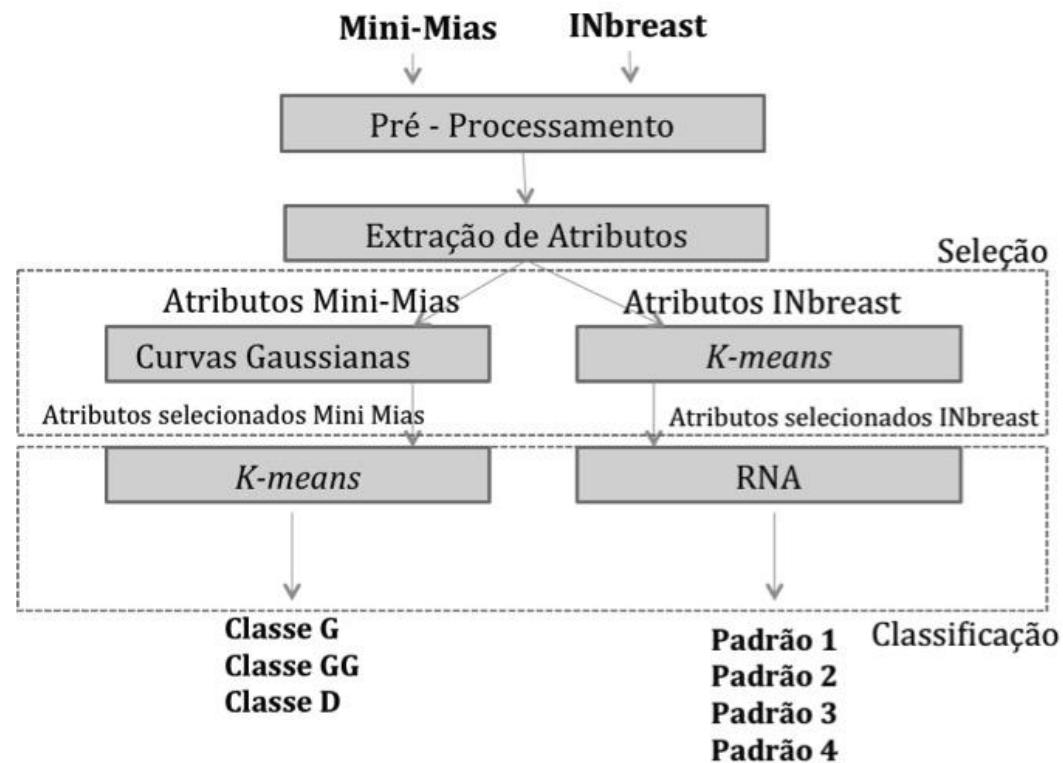
A utilização das imagens em filme serviu, inicialmente, para avaliar os atributos de intensidade e de textura na caracterização dos padrões de densidade mamária. Além disso, serviu para avaliar o *k-means* como técnica de classificação das imagens em filme e, posteriormente, como técnica de seleção para as imagens digitais.

Ainda como técnica de classificação, foi utilizado Redes Neurais Artificiais, tendo como entrada do classificador os atributos extraídos das imagens digitais do banco INbreast.

Na etapa de processamento das imagens, foram utilizados os softwares ImageJ (ABRAMOFF, MAGALHÃES, RAM, 2004) e MATLAB (BEALE, HOGAN, DEMUTH, 2015).

A Figura 5.1 mostra um diagrama resumindo a etapa de processamento das imagens, quais as técnicas utilizadas para seleção de atributos e qual o método utilizado para classificar as imagens em classes.

Figura 5.1 – Diagrama resumo da etapa de processamento das imagens.



5.1 Banco de imagens

5.1.1 Banco de imagens Mini-MIAS

As imagens utilizadas no primeiro teste foram obtidas do banco virtual mini-MIAS (SUCKLING *et al.*, 1994). Este banco possui imagens em filme digitalizados, de 8 bits de resolução de contraste, com tamanho 1024 x 1024 pixels. Estas imagens já vêm laudadas, possuindo informações detalhadas, tais como: presença ou não de lesão, tipo de lesão (se presente), classificação da lesão (maligna ou benigna) e também padrão de densidade mamária.

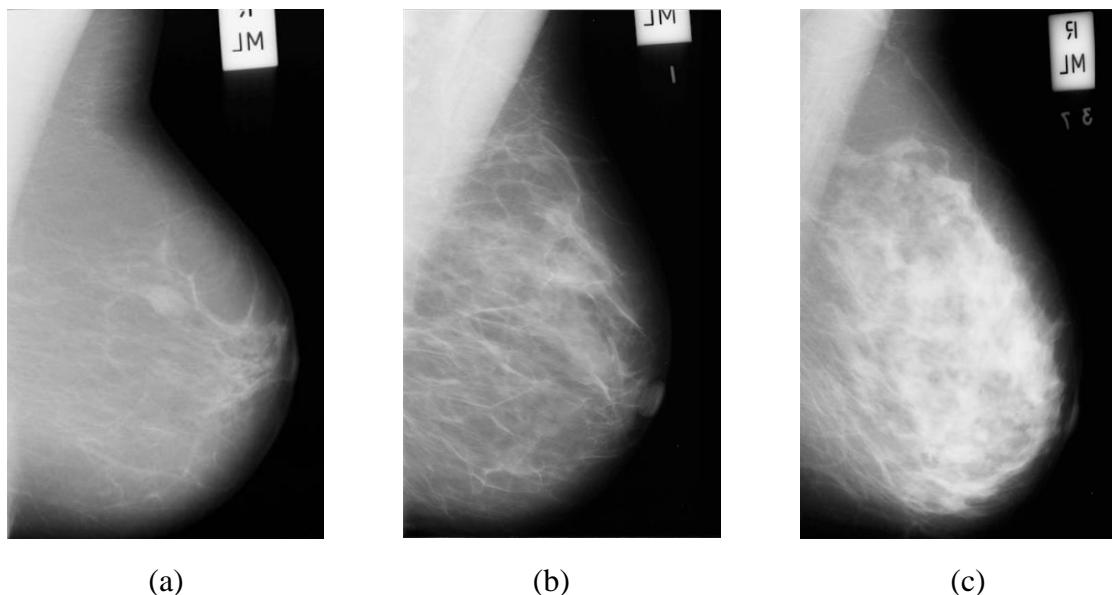
No entanto, a classificação destas imagens se deu em três classes de densidade mamária, sendo elas:

- G: classe gordurosa;
- GG: classe gordurosa-glandular;
- D: classe densa (glandular).

Ao contrário do atual sistema BI-RADS™ que propõe a classificação em quatro padrões, nesta primeira etapa, a proposta foi classificar as imagens nestas três classes: gordurosa, gordurosa-glandular e densa (glandular). Para este experimento foram usadas 75 imagens, 25 pertencentes a cada um dos padrões, sendo todas elas sob vista médio-lateral oblíquas (MLO).

A Figura 5.2 apresenta algumas imagens do banco virtual mini-MIAS (sem pré-processamento) utilizadas neste primeiro teste, com um exemplo de imagem para cada uma das três classes de padrão de densidade mamária.

Figura 5.2 – Banco mini-MIAS: exemplo de imagens pré-processadas das três classes de densidade mamária. (a) Classe gordurosa. (b) Classe gordurosa-glandular. (c) Classe densa.



5.1.2 Banco de imagens INbreast

O segundo teste foi realizado com imagens mamográficas digitais extraídas do banco virtual INbreast, provenientes do Centro Hospitalar de São João em Porto, Portugal (MOREIRA *et al.*, 2012). Todas estas imagens foram obtidas do mesmo equipamento, um mamógrafo *MammoNovation FFDM* da marca *Siemens*, de 12 bits de resolução de contraste. Os mamogramas têm tamanho de 3328 x 4084 ou 2560 x 3328 pixels, dependendo da compressão da mama (de acordo com o tamanho da mama da paciente). As imagens foram salvas no padrão DICOM (*Digital Imaging and Communications in Medicine*), sendo que as informações médicas foram removidas respeitando o princípio da confidencialidade.

Neste banco de imagens, os mamogramas foram laudados por dois radiologistas experientes (dupla leitura), sendo usada a padronização proposta na quarta edição do BI-RADS™ para caracterizar a densidade mamária dos mamogramas. As quatro categorias do BI-RADS™ usadas no banco INbreast são:

- **1:** Mamas predominantemente adiposas (25% do componente fibroglandular);
- **2:** Mamas parcialmente gordurosas (com densidades de tecido fibroglandular ocupando de 26% a 50% do volume da mama);
- **3:** Mamas com padrão denso e heterogêneo (51% a 75% de tecido fibroglandular);

- **4:** Mamas muito densas, apresentando mais de 75% de tecido fibroglandular.

Foram utilizadas 307 imagens mamográficas digitais provenientes deste banco, sendo estas tanto sob vista médio-lateral oblíquas (MLO), quanto sob vista crânio-caudal (CC). A Tabela 5.1 mostra a quantidade de imagens pertencente a cada padrão que foi utilizada neste segundo teste.

Tabela 5.1 – INbreast: distribuição da quantidade de imagens pertencentes a cada padrão de densidade mamária.

| Imagens | Padrão 1 | Padrão 2 | Padrão 3 | Padrão 4 |
|--------------|----------|----------|----------|----------|
| MLO | 51 | 52 | 36 | 13 |
| CC | 52 | 52 | 37 | 14 |
| Total | 103 | 104 | 73 | 27 |

As Figuras 5.3 e 5.4 apresentam exemplos de imagens dos diferentes padrões de densidade deste banco de imagens, em ambas as vistas MLO e CC.

Figura 5.3 – INbreast: imagens sob vista MLO. (a) Padrão 1: gorduroso. (b) Padrão 2: . (c) Padrão 3. (d) Padrão 4: denso

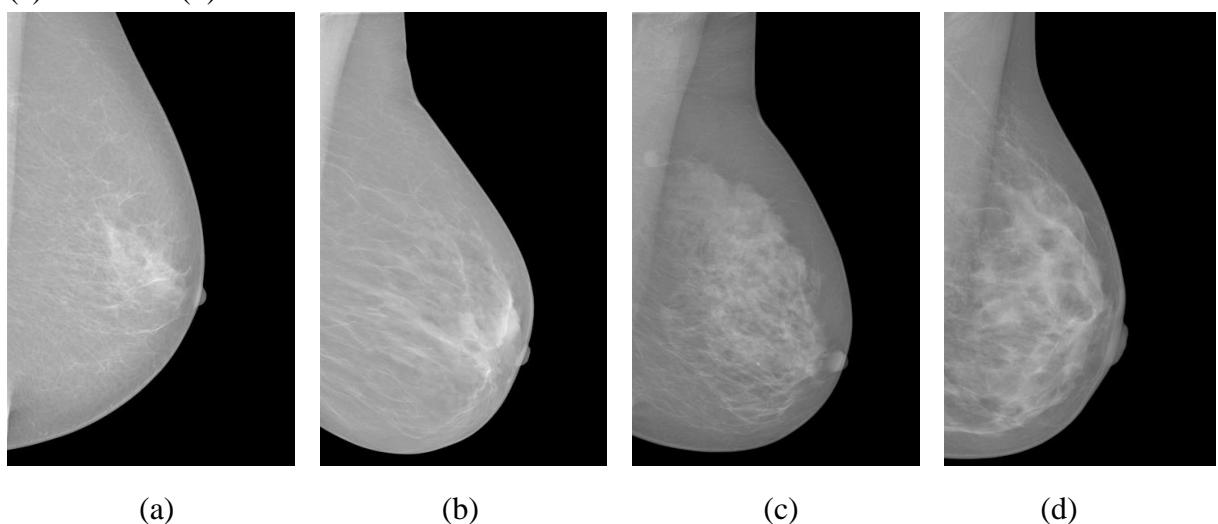
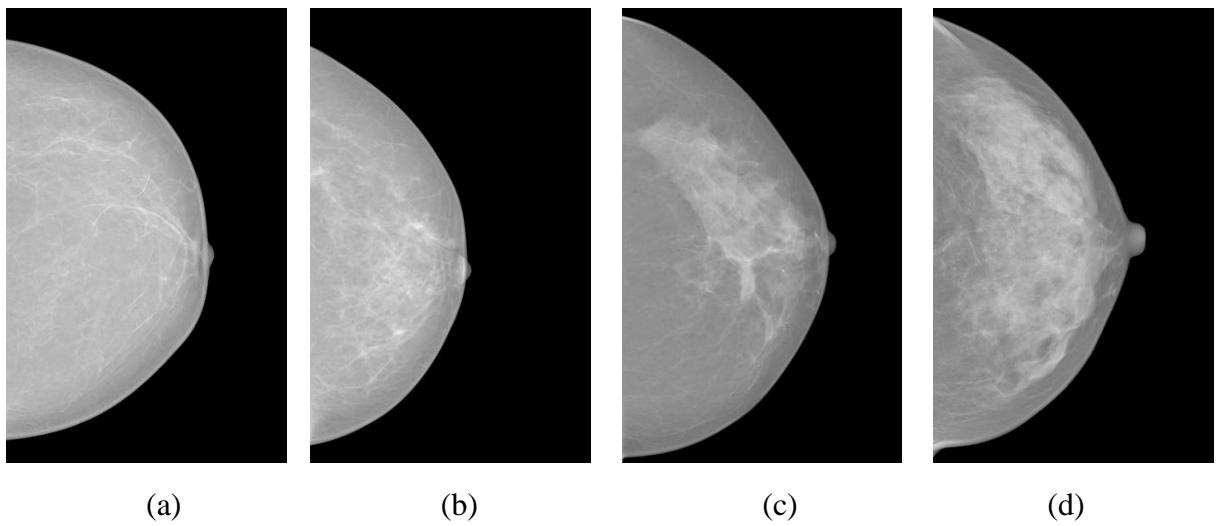


Figura 5.4 – INbreast: imagens sob vista CC. (a) Padrão 1: gorduroso. (b) Padrão 2: 26-50% de tecido fibroglandular. (c) Padrão 3: 51% a 75% de tecido fibroglandular. (d) Padrão 4: denso.



5.2 Extração de atributos

5.2.1 Pré-processamento das imagens

Antes da etapa de extração de atributos, para as imagens do banco Mini-MIAS, foi feito um pré-processamento das imagens com o auxílio do *software* ImageJ (ABRAMOFF, MAGALHÃES, RAM, 2004). Este pré-processamento consistiu na retirada de informações de texto (etiquetas) que vinham na imagem, além da segmentação do músculo peitoral. Estas regiões foram delimitadas manualmente e transformadas, então, em região de “fundo” da imagem, isto é, em preto absoluto (pixel com valor de intensidade igual a zero). A Figura 5.5 abaixo mostra as imagens antes do pré-processamento (a) e após o pré-processamento (b).

Além da segmentação descrita acima, pixels de valor de intensidade de tons de cinza inferiores a três foram desconsiderados dos cálculos, com base em (MUSTRA, GRGIC, DELAC, 2012), de modo a considerar apenas a área útil da mama. Estes valores foram considerados como fundo de imagem, visto que não existem tecidos nessa faixa de nível de cinza, provavelmente então sendo ruído nas imagens.

Dessa forma, todas as 75 imagens, do primeiro teste, foram pré-processadas, para assim, partir para a etapa de extração de atributos. A Figura 5.6 mostra as imagens dos três padrões de densidade após a etapa de segmentação feita no pré-processamento.

Figura 5.5 – Segmentação das imagens: (a) Imagem original. (b) Imagem segmentada: retirada do músculo peitoral e de informações em texto.

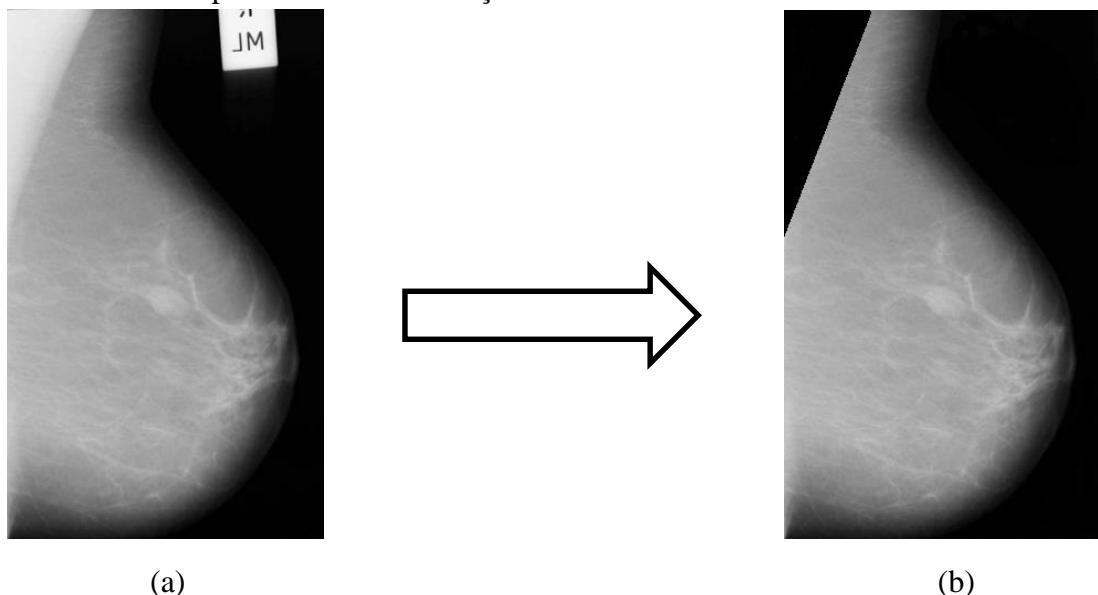
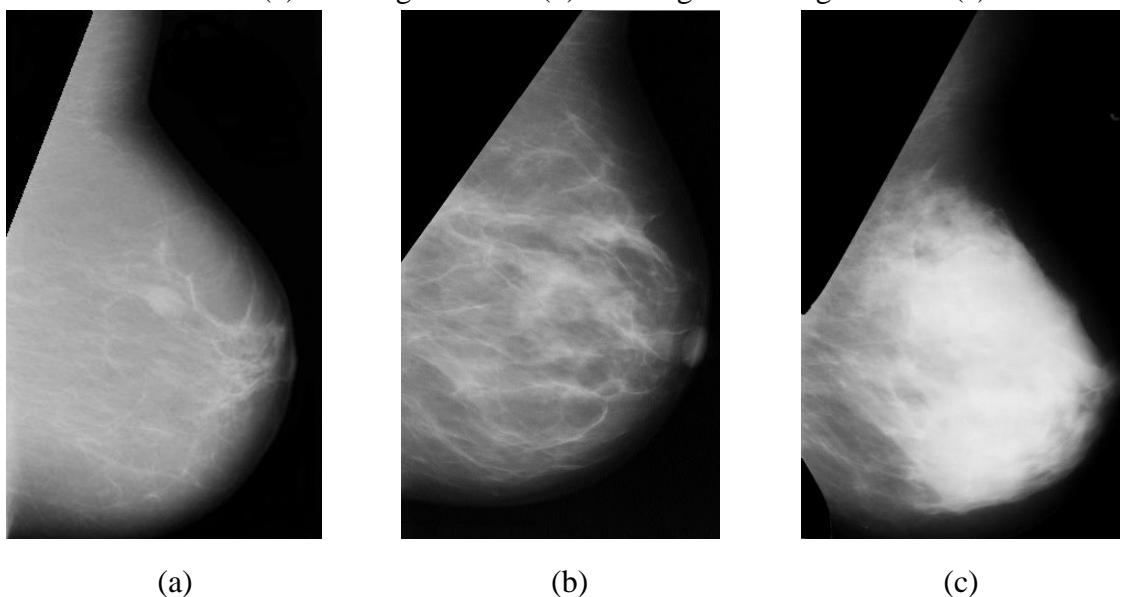


Figura 5.6 – Banco mini-MIAS: exemplo de imagens pré-processadas das três classes de densidade mamária. (a) Classe gordurosa. (b) Classe gordurosa-glandular. (c) Classe densa.



Já para as imagens digitais, do banco INbreast, a etapa de pré-processamento consistiu apenas em desconsiderar o fundo, isto é, pixels com valores de nível de cinza igual a zero (preto absoluto) foram desprezados, e os atributos, extraídos apenas da área glandular da mama, isto é, pixels com valores de nível de cinza superiores à zero.

5.2.2 Extração de atributos de intensidade (histograma) e descritores de textura de Haralick

Com o pré-processamento realizado, partiu-se para a etapa da extração de atributos, tanto das imagens em filme do banco Mini-MIAS, quanto das imagens digitais do banco INbreast. Os atributos foram extraídos a partir de implementação de rotinas realizadas no software MATLAB. Neste estágio, as imagens em filme pré-processadas (8 bits) são inseridas no software e convertidas para tons de cinza, com seus pixels variando de 0 a 255. Já as imagens do banco INbreast, no padrão DICOM, de 12 bits de resolução, os pixels variam de 0 a 4095.

Nos dois testes (imagens em filme e imagens digitais) foram extraídos tanto atributos baseados em histograma, bem como atributos de textura, sendo estes explicados no Capítulo anterior. Para os atributos de intensidade, todos os cálculos são feitos com base no histograma da imagem, gerando assim nove atributos, tais como:

1. Média de níveis de cinza;
2. Intensidade do pico do histograma (moda);
3. Menor intensidade de pixel do histograma;
4. Maior intensidade de pixel do histograma;
5. Diferença da média de níveis de cinza para o menor valor;
6. Diferença da média de níveis de cinza para o maior valor (módulo);
7. Porcentagem da maior intensidade do histograma em relação à intensidade máxima possível;
8. Número de pixels maior que o pico do histograma
9. Diferença entre a maior e a menor intensidade (gradiente)

Como cada imagem obtém um valor para cada um dos nove atributos extraídos, foi feita uma média aritmética simples dos atributos normalizados de imagens de mesma classe (padrão), podendo assim comparar os resultados entre elas. Além da média, foi calculado também o desvio padrão de cada classe.

Já os atributos de textura extraídos foram os 14 descritores de Haralick, com base na matriz de coocorrência calculada assim que as imagens (matrizes) são inseridas no software. O ângulo e também a distância dos pixels considerados no cálculo da matriz de coocorrência

podem ser variados. Porém, neste trabalho a distância escolhida foi de 1 (unitária), e a extração dos atributos foi feita para os quatro ângulos (0° , 45° , 90° e 135°).

O resultado final de cada atributo é produzido pela média aritmética do resultado obtido para as quatro angulações, com a distância unitária.

Assim como para os atributos extraídos do histograma, para os descritores de textura de Haralick, foi feita uma média aritmética por classe, bem como o cálculo do desvio padrão de cada classe.

Os 14 descritores de textura de Haralick extraídos foram:

1. Uniformidade ou Energia;
2. Contraste;
3. Correlação;
4. Variância;
5. Momento da diferença inversa;
6. Média da soma;
7. Variância da soma;
8. Entropia da soma;
9. Entropia;
10. Variância da diferença;
11. Entropia da diferença;
12. Medida de informação de correlação 1;
13. Medida de informação de correlação 2;
14. Máximo coeficiente de correlação.

5.3 Seleção de atributos

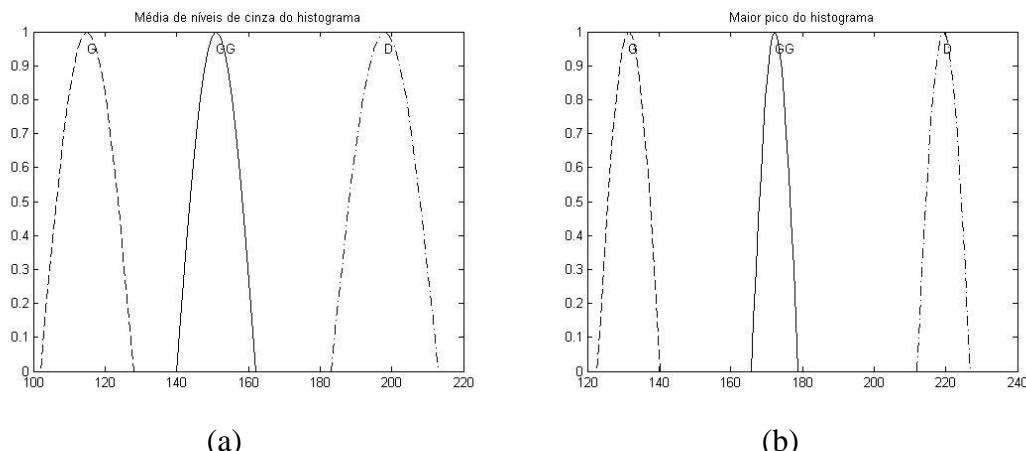
A seleção de atributos foi feita utilizando a curva gaussiana para as imagens em filme do banco Mini-MIAS, e para as imagens digitais do banco INbreast, foi utilizado o método de *clustering k-means*, conforme será detalhado nas próximas seções. Ambos os métodos de seleção foram calculados e construídos a partir de rotinas implementadas no software MATLAB.

5.3.1 Distribuição normal (Gaussiana)

Após a extração de atributos, torna-se necessária a etapa de seleção destes, a fim de reduzir a dimensionalidade dos dados, melhorando o custo computacional, e direcionando melhores atributos a serem utilizados na etapa de classificação. No caso das imagens em filme, a técnica proposta para seleção dos atributos foi a construção da distribuição normal (curva gaussiana), a partir da média e desvio padrão dos dados normalizados. Tal técnica consiste em uma análise visual dos gráficos gerados, sendo que quanto menor a sobreposição das curvas, melhor o atributo será na classificação das imagens. Sendo assim, foi gerada uma curva gaussiana para cada um dos atributos extraídos do histograma e de textura.

A Figura 5.7 apresenta as curvas dos dois melhores atributos de intensidade (média de níveis de cinza e maior pico do histograma) e dos dois melhores descritores de textura (uniformidade e correlação) a partir da análise visual das curvas gaussianas. Já a Figura 5.8 mostra exemplos de atributos de intensidade e textura em que provavelmente a classificação não terá tanta eficácia, visto que as curvas se sobrepõem entre si. Estes atributos foram: menor intensidade de pixel, gradiente, variância e entropia da diferença. Cada uma das classes está representada por um tracejado diferente, de forma a facilitar a diferenciação.

Figura 5.7 – Curvas gaussianas com boa separabilidade entre as classes. (a) Média de níveis de cinza do histograma. (b) Maior pico do histograma. (c) Uniformidade. (d) Correlação.



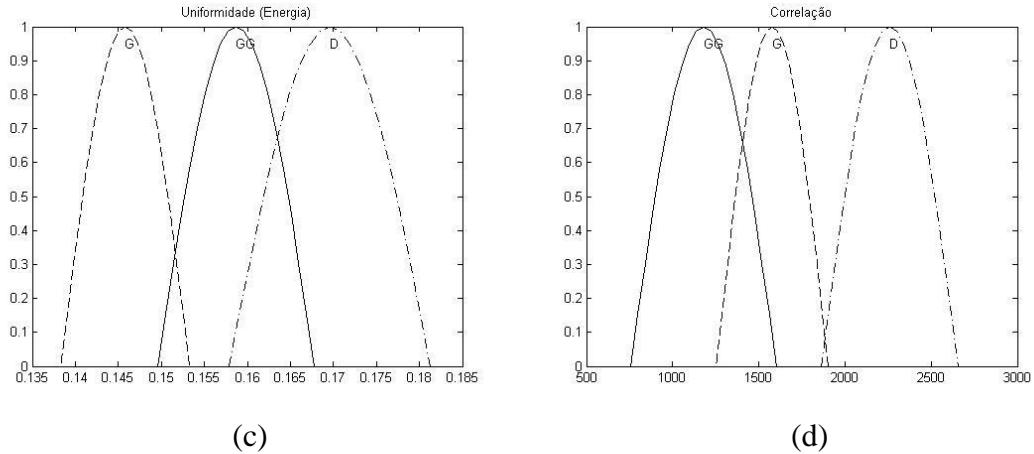
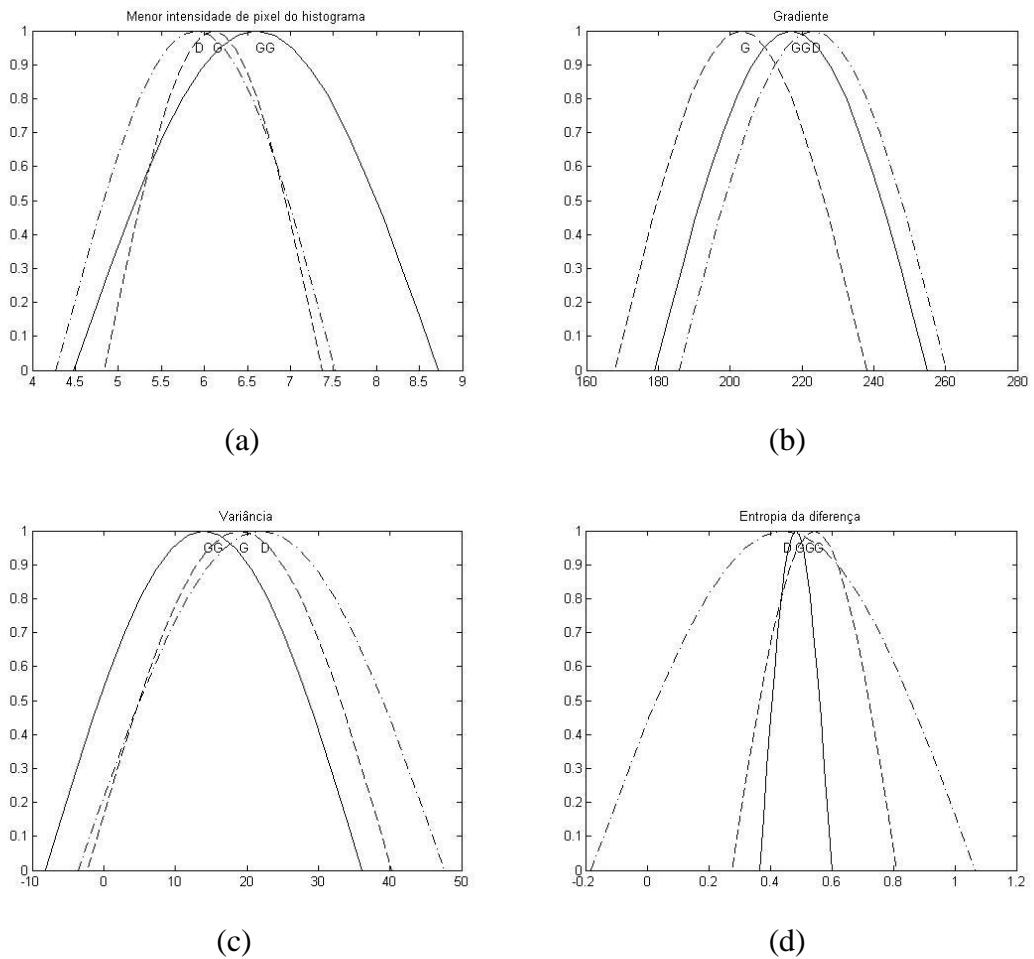


Figura 5.8 – Curvas gaussianas com separabilidade ruim entre as classes. (a) Menor intensidade de pixel do histograma. (b) Gradiente. (c) Variância. (d) Entropia da diferença.



De forma geral, é possível verificar que as melhores curvas gaussianas dos atributos de textura (Figura 5.7 ‘c’ e ‘d’), aparentemente não classificariam as imagens dentro das três classes com muita eficiência. Isso é comprovado pela sobreposição, mesmo que pequena, entre as curvas gaussianas das diferentes classes. No entanto, as curvas gaussianas dos atributos extraídos do histograma (Figura 5.7 ‘a’ e ‘b’), não apresentam nenhum ponto de

sobreposição, indicando serem possíveis bons atributos no momento da classificação dentre as três classes de padrão de densidade das imagens do Mini-MIAS.

5.3.2 *K-means* para seleção de atributos

O *k-means* é uma técnica de *clustering* geralmente utilizada para agrupamento de dados dentre um número pré-estabelecido de classes. Entretanto, neste trabalho, além de utilizá-lo como método de classificação, ele foi usado também como técnica de seleção de atributos para as 307 imagens do banco digital INbreast.

Para tal, todos os 23 atributos (atributos de intensidade e de textura) foram testados individualmente na técnica de *k-means*, além do teste da combinação de alguns atributos. O número de *clusters* usado foi igual a quatro, mesmo número de classes de densidade mamária em que as imagens deveriam ser classificadas. Os diversos testes resultaram em grupos de atributos com boa taxa de acerto na separação das classes, ou seja, foi considerado como significante o atributo que resultou em maior acerto na separação das quatro classes.

No Capítulo 7, serão apresentadas as taxas de acertos dos diversos testes implementados com o *k-means*, e quais grupos de atributos foram utilizados como dado de entrada na Rede Neural Artificial proposta.

5.4 Classificação das imagens

5.4.1 *K-means* como classificador

Após o pré-processamento, extração e seleção dos atributos por curvas gaussianas, as imagens de 8 bits de resolução de contraste do banco virtual Mini-MIAS foram classificadas a partir da técnica de *k-means*. Tal técnica de agrupamento foi implementada no software MATLAB, no qual basta entrar com os atributos a serem testados, escolher o número de *clusters* (neste caso, três), e de maneira iterativa, o método busca minimizar o erro quadrático médio, classificando as imagens.

A saída do *k-means* é a classe proposta pela técnica em que a imagem deve pertencer. Então, basta comparar a classe fornecida pelo *k-means*, com a classe (padrão) original da imagem, podendo assim calcular a taxa de acerto do classificador.

A classificação foi feita de forma que os atributos foram inseridos (vetor de entrada da técnica) um a um verificando a taxa de acerto. Após esse processo, os melhores atributos foram então combinados a fim de se obter novas taxas de acerto, verificando se a combinação destes atributos melhorariam os resultados.

5.4.2 Redes Neurais Artificiais

A classificação das imagens digitais (INbreast) foi feita utilizando um modelo de Rede Neural Artificial (RNA). O objetivo é classificar as imagens nas quatro categorias de padrão de densidade mamária existentes, e verificar se essas imagens foram alocadas na sua classe correta.

A RNA foi implementada usando o *toolbox* de redes neurais do *software* MATLAB (BEALE, HOGAN, DEMUTH, 2015). Dentre os diversos modelos de redes neurais existentes, neste trabalho, optou-se pela utilização da Rede Neural Artificial supervisionada *feedforward*, com algoritmo de aprendizagem por *backpropagation*. Nas redes neurais deste tipo (*feedforward*), o sinal percorre a rede em uma única direção, da entrada para a saída, ou seja, os neurônios de mesma camada não são conectados.

Foi usado um algoritmo de treinamento adaptativo que consiste na atualização tanto dos pesos quanto dos valores de *bias* de acordo com o gradiente variável, a partir da função do MATLAB *traingdx*. O algoritmo de *backpropagation* é usado de forma a calcular as derivadas da performance ('*perf*') no que diz respeito às variáveis de peso e *bias* ('*X*'). Cada variável é ajustada de acordo com o gradiente, no qual '*mc*' é o momento constante, '*dXprev*' é a alteração anterior ao peso e *bias*, e '*lr*' é a taxa de aprendizagem, conforme a equação 5.1:

$$dX = (mc \cdot dXprev) + (lr \cdot mc \cdot \frac{dperf}{dX}) \quad (5.1)$$

A partir dessa *toolbox* do MATLAB, é possível propor diversas configurações para a rede neural, variando o número de neurônios das camadas de entrada, intermediária e de saída, o número de épocas, gradiente mínimo (erro quadrático máximo), o número máximo de falhas de validação, além da função de ativação de cada camada.

O número de neurônios da camada de entrada correspondeu exatamente ao número de atributos a serem inseridos pela rede. Já para a camada intermediária, ou camada escondida, o

número de neurônios foi variado de 1 a 3 vezes o número de neurônios da camada inicial. Isso significa dizer que, se caso o número de atributos analisados fosse 5, o número de neurônios da camada intermediária variava de 5 até 15, testados um por um, até chegar na melhor configuração, gerando assim 11 redes testadas.

Como a classificação das imagens ocorre em quatro classes, é necessário que a camada de saída possua pelo menos dois neurônios, com saída binária. Para que os resultados de saída da rede atendessem à configuração binária, foi utilizada uma função de arredondamento para o inteiro mais próximo, possibilitando, então, que o resultado gerado pela rede, para cada neurônio, fosse sempre 0 ou 1.

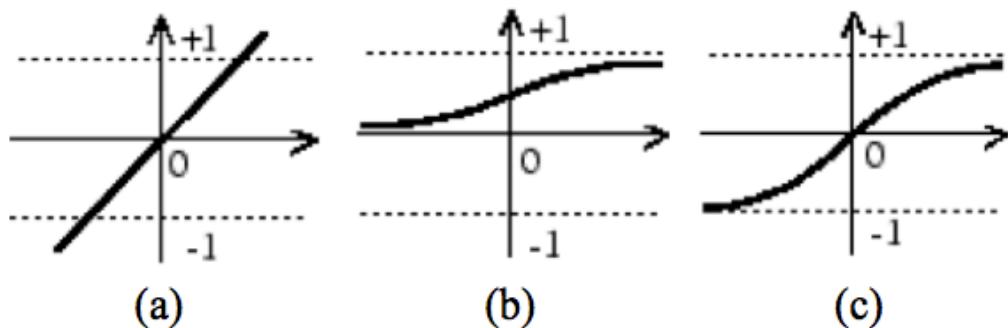
Assim, foi proposto que se determinada imagem resultasse em uma saída ‘00’, essa imagem pertencia ao padrão 1 de densidade mamária, se a saída fosse ‘01’, a imagem pertencia ao padrão 2 de densidade mamária, e saídas ‘10’ e ‘11’, aos padrões 3 e 4 de densidade mamária, respectivamente.

As épocas correspondem ao número de iterações de treinamento da rede, este número foi variado de 100.000 a 200.000 épocas. O gradiente mínimo (*min_grad*) usado foi de 10^{-6} , isto é, o gradiente vai diminuindo à medida que o treinamento atinge um valor máximo de desempenho. Se a magnitude do gradiente for menor que 10^{-6} , o treinamento da rede é interrompido.

O número máximo de falhas de validação (*validation checks*) foi variado de 10.000 à 100.000, representando o número de iterações sucessivas que a performance da validação falha ao tentar abaixar o erro.

Por fim, as funções de transferência, ou funções de ativação testadas foram: linear, log-sigmoidal (*logsig*) e tangente sigmoide hiperbólica (*tansig*). A função linear é aquela que possui fator de amplificação igual a 1 (fator unitário). A função *logsig* tem o formato sigmoidal e é uma função estritamente crescente que exibe um equilíbrio entre o desempenho linear e não linear. Já a função *tansig* é similar à *logsig*, diferenciando-se pelo fato de poder assumir valores no intervalo de [-1,1]. A Figura 5.9 apresenta o gráfico referente a cada uma das funções de transferência.

Figura 5.9 – Gráfico das funções de ativação testadas: (a) Linear, (b) *Logsig*, (c) *Tansig*.



Fonte: Modificado de (BEALE, HOGAN, DEMUTH, 2015).

O treinamento da rede era interrompido caso alguma das seguintes condições ocorressem:

- O número máximo de épocas (iterações) for atingido;
- Se a magnitude do gradiente for menor que o valor de *min_grad* escolhido;
- Se o número de *validation checks* for atingido;

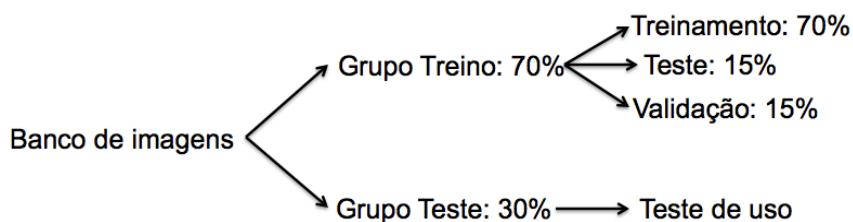
Antes de cada treinamento da RNA, o grupo de imagens é dividido aleatoriamente em grupo treino e grupo teste. Foi proposto que o grupo treino correspondesse a 70% da quantidade total de imagens de cada padrão de densidade mamária. Entretanto, na tentativa de uniformizar o número de imagens do grupo treino, calculou-se 70% do total de imagens pertencentes ao padrão 3 (51 imagens), e esse valor foi utilizado também para os padrões 1 e 2. Para o padrão 4, 70% das 27 imagens (19 imagens), foram alocadas ao grupo treino, e as 8 restantes ao grupo teste. A Tabela 5.2 apresenta de forma clara a quantidade de imagens de cada padrão usadas para grupo treino e teste.

Tabela 5.2 – Grupo Treino x Grupo Teste: Número de imagens referentes a cada padrão de densidade mamária.

| Grupo | Padrão 1 | Padrão 2 | Padrão 3 | Padrão 4 | Total |
|---------------|----------|----------|----------|----------|-------|
| Treino | 51 | 51 | 51 | 19 | 172 |
| Teste | 52 | 53 | 22 | 08 | 135 |

O grupo treino e o grupo teste foram gerados randomicamente antes que uma nova rede seja treinada. Após a divisão do grupo treino, uma parte deste é subdividido para treinamento (70%), outra para teste (15%) e para validação (15%), de maneira aleatória pelo MATLAB. Já o grupo teste não entra em contato com a fase de treinamento da rede, sendo usado para testar a eficiência da rede (teste de uso). Foram utilizadas 172 imagens no grupo treino e 135 do grupo teste. A Figura 5.10 resume a divisão do conjunto de imagens.

Figura 5.10 – RNA: diagrama com a divisão do conjunto de imagens em grupo treino e teste.



Depois que o melhor resultado é obtido, a configuração dos parâmetros (número de neurônios da camada intermediária, número de épocas, gradiente mínimo, *validation checks*) utilizados para essa RNA é salva e treinada por mais 10 vezes, gerando assim um resultado médio de taxa de acerto de classificação. Uma vez obtida uma determinada taxa de acerto, esse mesmo resultado pode ser conseguido novamente, a qualquer momento, desde que a mesma configuração seja usada e que os pesos gerados por essa rede sejam salvos.

A Tabela 5.3 abaixo resume de maneira geral a etapa de processamento das imagens, desde os bancos de mamogramas utilizados, até a classificação destes em classes de padrão de densidade mamária.

Tabela 5.3 – Resumo geral de todo o estágio de processamento das imagens.

| Banco de imagens | Pré- processamento | Extração de atributos | Seleção de atributos | Classificação |
|---|--|---|-----------------------------------|--------------------------------------|
| Mini-MIAS (8 bits) 75 imagens | Segmentação: - Músculo peitoral - Etiquetas - Pixels de fundo | 9 extraídos de histograma 14 descritores de Haralick | Curva gaussiana <i>K-means</i> | 3 classes: <i>K-means</i> |
| INbreast (12 bits) 307 imagens | Segmentação dos pixels de fundo | 9 extraídos de histograma 14 descritores de Haralick | <i>K-means</i> | 4 classes: Rede Neural Artificial |

Capítulo 6 ANÁLISE DE ATRIBUTOS

Os principais resultados obtidos pela aplicação dos procedimentos e técnicas apresentadas no Capítulo anterior, tais como extração e seleção de atributos estão apresentadas neste Capítulo 6.

Os resultados estão em ordem cronológica, para uma melhor compreensão das técnicas desenvolvidas e testadas. Isto significa dizer que em, um primeiro momento, serão expostos os resultados dos atributos extraídos para os testes feitos com as imagens em filme do banco virtual Mini-MIAS, e posteriormente, o resultados da extração e seleção de atributos para os testes realizados nas imagens digitais do banco INbreast.

Devido ao pré-processamento, as imagens em filme tiveram seus níveis de intensidade de pixel variando de quatro a 245, enquanto que nas imagens digitais esses valores variaram de no mínimo um até o valor 4095 de intensidade de pixel.

6.1 Análise de atributos das imagens em filme

A Tabela 6.1 apresenta a média aritmética simples (\bar{X}) dos atributos extraídos do histograma das 75 imagens em filme pré-processadas, além da média dos desvios padrão (σ) calculadas para cada uma das três classes.

Tabela 6.1 – Média aritmética e média dos desvios padrão dos atributos extraídos do histograma para imagens em filme.

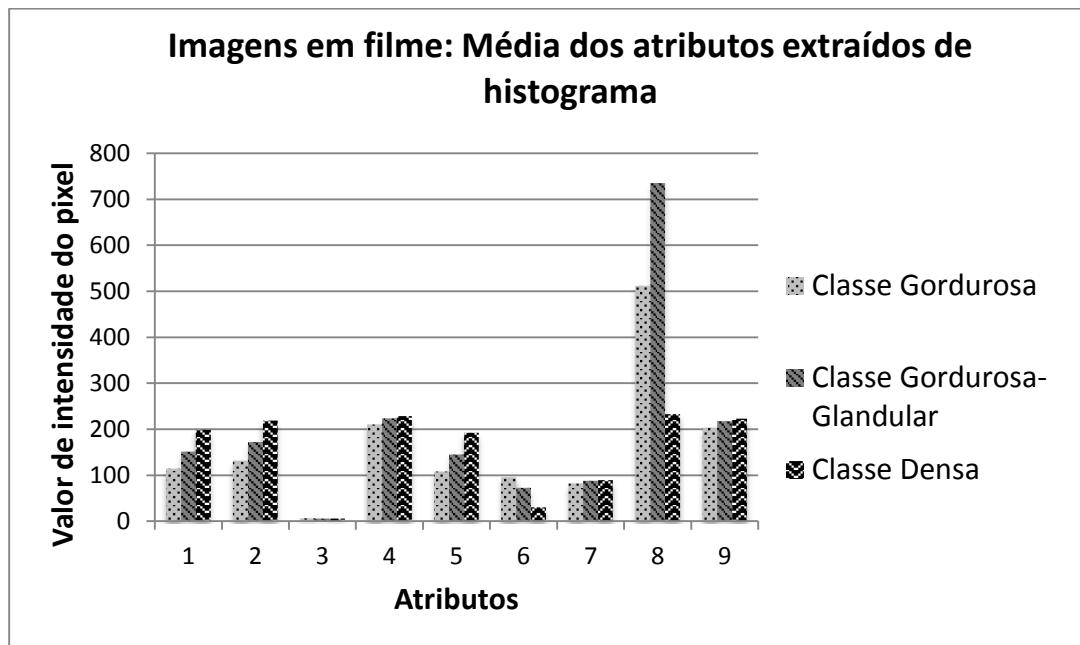
| Atributos extraídos do histograma | Classe | Gordurosa | Classe | Gordurosa-glandular | Classe | Densa |
|-----------------------------------|-----------|-----------|-----------|---------------------|-----------|----------|
| | \bar{X} | σ | \bar{X} | σ | \bar{X} | σ |
| 1. Média de níveis de cinza | 114,6 | 13,85 | 151,3 | 11,52 | 198,4 | 15,22 |
| 2. Maior pico do histograma | 131,8 | 8,75 | 172,3 | 7,24 | 219,1 | 9,91 |
| 3. Menor intensidade | 6,6 | 10,11 | 6,1 | 12,14 | 5,9 | 16,21 |
| 4. Maior intensidade | 210,2 | 22,36 | 223,8 | 20,45 | 228,6 | 18,97 |
| 5. Diferença da média para a | 108 | 28,32 | 145,2 | 19,47 | 192,5 | 25,53 |

| menor intensidade | 95,6 | 36,52 | 72,5 | 29,43 | 30,2 | 35,41 |
|---|---------------|--------|---------------|--------|--------------|-------|
| 6. Diferença da média para a maior intensidade | 95,6 | 36,52 | 72,5 | 29,43 | 30,2 | 35,41 |
| 7. % (Maior intensidade/245) | 82,43 | 12,83 | 87,86 | 10,06 | 89,64 | 11,84 |
| 8. N° de pixels acima do pico | 512,18 | 332,43 | 735,47 | 298,65 | 232,8 | 318,6 |
| 9. Gradiente | 203,6 | 35,52 | 217,7 | 38,42 | 222,7 | 37,73 |

Pela Tabela 6.1 observa-se que as imagens mamográficas, em filme, que foram processadas são bem definidas em termos de níveis de intensidade de pixel, isto é, conforme aumenta a predominância de tecido fibroglandular da mama, maior a quantidade de pixels com tons de cinza mais claros. Isto é comprovado pelo atributo 1 (média de níveis de cinza do histograma), visto que o valor para este atributo vai se elevando quanto mais densa é a mama.

Para uma melhor visualização foi construído um gráfico com os resultados obtidos para os atributos extraídos do histograma, conforme mostrado na Figura 6.1.

Figura 6.1 – Gráfico da média dos atributos extraídos do histograma por classe de densidade mamária.



A partir da Figura 6.1 podemos verificar que alguns atributos não devem diferenciar as imagens de diferentes classes muito bem, devido à similaridade dos valores destes atributos. Isto é observado, principalmente, pelo atributo ‘3’ (menor intensidade do histograma) e pelo atributo ‘7’ (porcentagem da maior intensidade em relação a intensidade máxima possível).

Outra análise pode ser feita a partir do coeficiente de variação de Pearson (CV), uma medida de dispersão relativa, empregada para estimar a variabilidade de uma amostra. Ele é calculado pela divisão do desvio padrão (σ) pela média (\bar{X}), podendo ser apresentada em porcentagem, conforme a Equação 6.1.

$$CV\% = \frac{S}{\bar{X}} \cdot 100 \quad (6.1)$$

Quanto menor o valor deste coeficiente em porcentagem, menor a variabilidade do atributo em relação à média dentro da classe analisada. Por exemplo, caso o coeficiente calculado seja igual a 10%, a interpretação é de que os desvios relativamente à média atingem 10% do valor dela.

A Tabela 6.2 apresenta os coeficientes de variação, em porcentagem, calculados com base nos valores da média aritmética e desvio padrão dos atributos extraídos do histograma apresentado na Tabela 6.1. A Classe G corresponde à classe gordurosa, a classe GG à classe gordurosa-glandular e a classe D à classe densa.

Tabela 6.2 – Coeficiente de variação (porcentagem) dos atributos extraídos do histograma para as imagens em filme.

| Atributos extraídos do histograma | Classe G | Classe GG | Classe D |
|---|----------|-----------|----------|
| 1. Média de níveis de cinza | 12,09 | 7,61 | 7,67 |
| 2. Maior pico do histograma | 6,64 | 4,20 | 4,52 |
| 3. Menor intensidade | 153,18 | 199,02 | 274,75 |
| 4. Maior intensidade | 10,64 | 9,14 | 8,30 |
| 5. Diferença da média para a menor intensidade | 26,22 | 13,41 | 13,26 |
| 6. Diferença da média para a maior intensidade | 38,20 | 40,59 | 117,25 |
| 7. Porcentagem da maior intensidade em relação à intensidade máx. possível | 15,56 | 11,45 | 13,21 |
| 8. N° de pixels acima do pico | 64,90 | 40,61 | 136,86 |
| 9. Gradiente | 17,45 | 17,65 | 16,94 |

O atributo ‘3’ (menor intensidade do histograma), por exemplo, além de apresentar a média aritmética de atributos similares entre as classes, apresentam alto CV (maior que 150%), visto que os desvios padrão para as classes são maiores do que o próprio valor médio do atributo.

Já para o atributo 2 (maior pico do histograma), o CV é de aproximadamente 6,6% para Classe Gordurosa, 4,2% para a Classe Gordurosa-Glandular e 4,5% para a Classe Densa, confirmando a pouca variação destes dados em relação à média.

Os valores encontrados para a média aritmética e média dos desvios padrão para os descritores de textura de Haralick das imagens em filme são apontados na Tabela 6.3.

Tabela 6.3 – Média aritmética e média dos desvios padrão dos atributos de textura de Haralick para as imagens em filme.

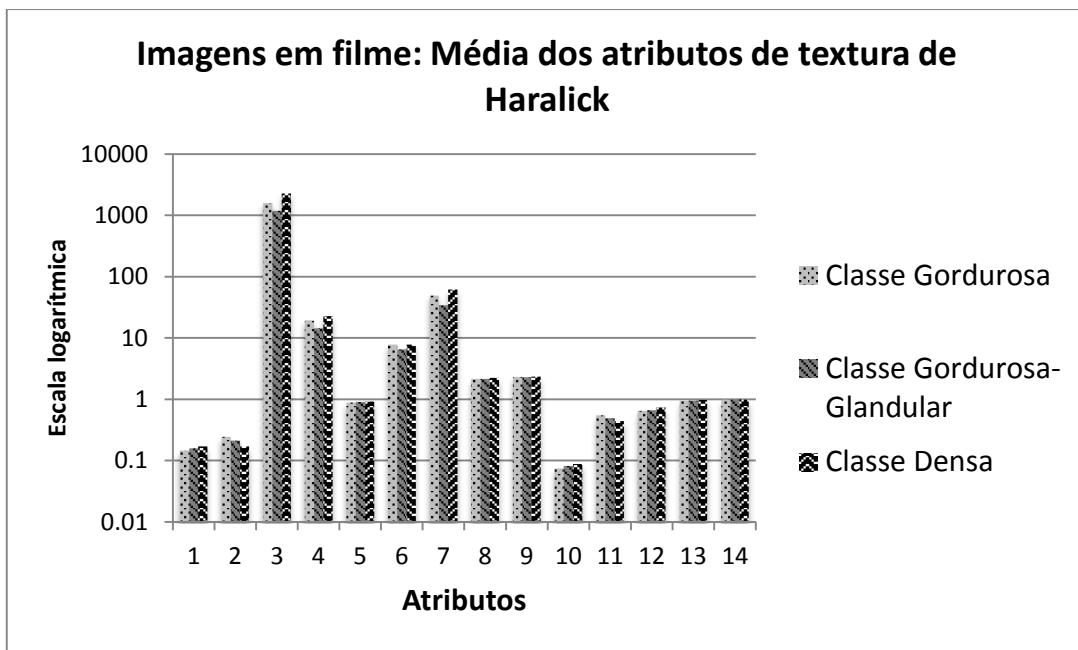
| Atributos de textura de Haralick | Classe | Gordurosa | Classe | Gordurosa-glandular | Classe | Densa |
|--|----------------|-----------|----------------|---------------------|----------------|----------|
| | \bar{X} | σ | \bar{X} | σ | \bar{X} | σ |
| 1. Uniformidade | 0,1458 | 0,0073 | 0,1587 | 0,0091 | 0,1696 | 0,0117 |
| 2. Contraste | 0,2446 | 0,0821 | 0,2115 | 0,0765 | 0,1694 | 0,0498 |
| 3. Correlação | 1578 | 324,78 | 1180,7 | 425,15 | 2260,4 | 398,42 |
| 4. Variância | 19,42 | 22,38 | 14,36 | 17,85 | 22,71 | 20,37 |
| 5. Momento da diferença inversa | 0,8825 | 0,3812 | 0,9071 | 0,4872 | 0,9217 | 0,2993 |
| 6. Média da soma | 7,82 | 1,81 | 6,5136 | 1,73 | 7,8138 | 2,08 |
| 7. Variância da soma | 48,93 | 11,56 | 34,30 | 12,94 | 61,30 | 20,19 |
| 8. Entropia da soma | 2,1423 | 0,0107 | 2,1446 | 0,0918 | 2,2285 | 0,0989 |
| 9. Entropia | 2,3069 | 0,0302 | 2,2801 | 0,0193 | 2,3417 | 0,0211 |
| 10. Variância da diferença | 0,0739 | 0,0277 | 0,0820 | 0,0438 | 0,0874 | 0,0386 |
| 11. Entropia da diferença | 0,5485 | 0,2522 | 0,4895 | 0,1039 | 0,4413 | 0,4907 |
| 12. Infº de correlação 1 | -0,6453 | 0,9984 | -0,6594 | 0,9612 | -0,7405 | 0,9042 |
| 13. Infº de correlação 2 | 0,9428 | 0,7834 | 0,9509 | 0,7863 | 0,9677 | 0,8081 |
| 14. Máx. coef. correlação | 0,9875 | 0,8510 | 0,9804 | 0,9104 | 0,9915 | 0,8144 |

A Figura 6.2 representa o gráfico da média aritmética dos atributos de textura de Haralick. Nestes gráficos, foi utilizada uma escala logarítmica, em vez da grandeza real dos atributos. A apresentação de dados em uma escala logarítmica se torna útil, visto que os dados cobrem uma grande e diferente gama de valores, e o logaritmo reduz a representação em uma escala mais fácil de ser visualizada.

Pelo gráfico da Figura 6.2, é possível perceber que a maioria dos atributos de textura possuem valores de média aritmética muito próximos entre as diferentes classes, dificultando a classificação. Isso provavelmente acontece, já que nas imagens em filme, as texturas dos

diferentes padrões não são tão bem representadas, sendo o tipo de tecido mais facilmente diferenciado pelo seu nível de cinza e não pela textura.

Figura 6.2 – Gráfico da média dos descritores de textura por classe de densidade mamária.



A Tabela 6.4 apresenta os coeficientes de variação calculados a partir da média aritmética e dos desvios padrão resultados da extração dos atributos de textura. Para o atributo ‘12’ (Medida de informação de correlação 1), o cálculo do CV foi realizado com o módulo da média aritmética, para que o valor ficasse positivo.

Tabela 6.4 – Coeficiente de variação (porcentagem) dos atributos de textura para as imagens em filme.

| Atributos de textura de Haralick | Classe G | Classe GG | Classe D |
|--|----------|-----------|----------|
| 1. Uniformidade | 5,01 | 5,73 | 6,90 |
| 2. Contraste | 33,57 | 36,17 | 29,40 |
| 3. Correlação | 20,58 | 36,01 | 17,63 |
| 4. Variância | 115,24 | 124,30 | 89,70 |
| 5. Momento da diferença inversa | 43,20 | 53,71 | 32,47 |
| 6. Média da soma | 23,15 | 26,56 | 26,62 |
| 7. Variância da soma | 23,63 | 37,73 | 32,94 |
| 8. Entropia da soma | 0,50 | 4,28 | 4,44 |
| 9. Entropia | 1,31 | 0,85 | 0,90 |
| 10. Variância da diferença | 37,48 | 53,41 | 44,16 |
| 11. Entropia da diferença | 45,98 | 21,23 | 111,19 |
| 12. Infº de correlação 1* | 154,72 | 145,77 | 122,11 |

| | | | |
|----------------------------------|-------|-------|-------|
| 13. Infº de correlação 2 | 83,09 | 82,69 | 83,51 |
| 14. Máx. coef. correlação | 86,18 | 92,86 | 82,14 |

* Foi calculado a partir do módulo do atributo.

A partir da Tabela 6.4 nota-se que os atributos '4' (variância) e '12' (medida de informação de correlação 1) são os que apresentam maior dispersão entre a mesma classe, enquanto os atributos '1' (uniformidade), '8' (entropia da soma) e '9' (entropia) foram os que apresentaram menor variabilidade em relação à média.

6.2 Resultados da seleção dos atributos das imagens em filme

Conforme explicado no Capítulo anterior, a seleção dos atributos das imagens em filme foi feita com o auxílio das curvas gaussianas. Com a construção dessas distribuições normais (mostradas no Capítulo 5) foi possível detectar os melhores atributos que poderiam ser utilizados como dado de entrada do algoritmo *k-means*.

Os atributos extraídos do histograma selecionados foram:

- Média de níveis de cinza (1);
- Maior pico do histograma (2);
- Maior intensidade do histograma (4).

Já os atributos de textura que apresentaram menor sobreposição das curvas gaussianas foram:

- Uniformidade (1);
- Contraste (2);
- Correlação (3);

6.3 Análise dos atributos das imagens digitais

Assim como foi feito para as 75 imagens em filme, a extração de atributos, e os cálculos da média aritmética e média de desvio padrão por classe de densidade mamária também ocorreu para as 307 imagens digitais do banco INbreast. A Tabela 6.5 apresenta os resultados para os atributos extraídos do histograma.

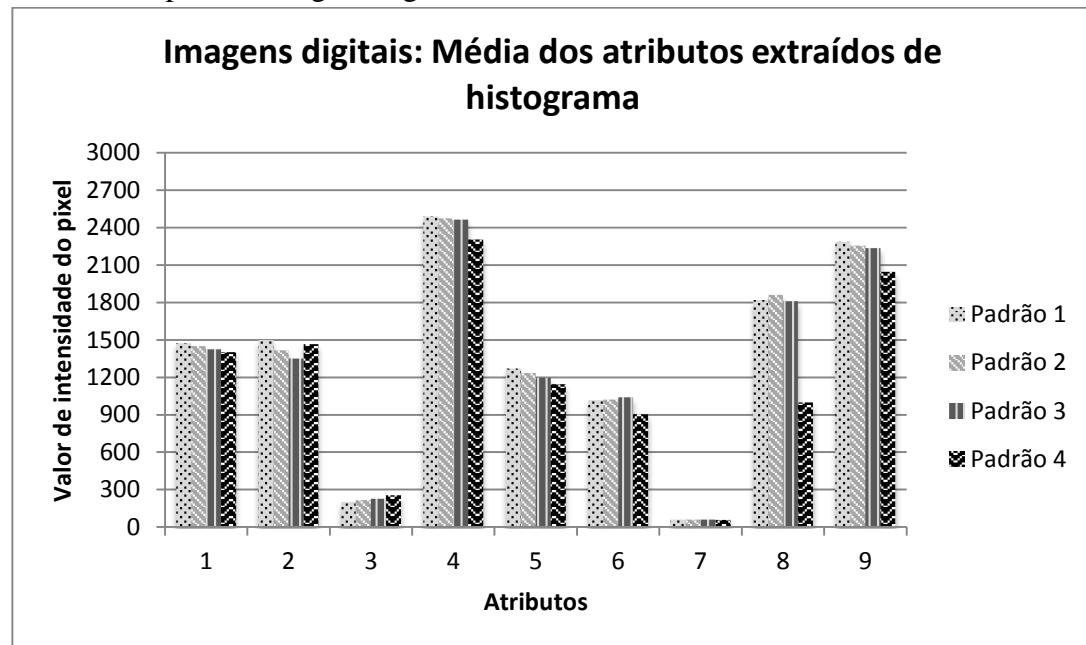
Tabela 6.5 – Média aritmética e média dos desvios padrão dos atributos extraídos do histograma para imagens digitais.

| Atributos extraídos do histograma | Padrão 1 | | Padrão 2 | | Padrão 3 | | Padrão 4 | |
|---|-------------------|----------------|-------------------|----------------|-------------------|----------------|------------------|----------------|
| | \bar{X} | σ | \bar{X} | σ | \bar{X} | σ | \bar{X} | σ |
| 1. Média de níveis de cinza | 1472,1 | 36,13 | 1451,3 | 57,13 | 1424,3 | 43,16 | 1401 | 67,27 |
| 2. Maior pico do histograma | 1498,5 | 40,02 | 1415,8 | 90,6 | 1351 | 129,14 | 1465 | 121,4 |
| 3. Menor intensidade | 201,83 | 177,9 | 217,64 | 173,3 | 227,54 | 127,03 | 255,88 | 109,1 |
| 4. Maior intensidade | 2489,3 | 249,2 | 2473 | 281 | 2463,6 | 253,79 | 2305,1 | 241,1 |
| 5. Diferença da média para a menor intensidade | 1270,3 | 183,0 | 1233,7 | 185,5 | 1196,8 | 125,72 | 1145,1 | 109,5 |
| 6. Diferença da média para a maior intensidade | 1017,2 | 249,9 | 1021,7 | 287,35 | 1039,3 | 257,16 | 904,06 | 251,2 |
| 7. Porcentagem da maior intensidade em relação à intensidade máx. possível | 60,78 | 6,08 | 60,39 | 6,86 | 60,16 | 6,19 | 56,29 | 5,8 |
| 8. N° de pixels acima do pico | $1,82 \cdot 10^6$ | $5 \cdot 10^5$ | $1,86 \cdot 10^6$ | $6 \cdot 10^5$ | $1,81 \cdot 10^6$ | $7 \cdot 10^5$ | $1,1 \cdot 10^6$ | $5 \cdot 10^5$ |
| 9. Gradiente | 2287,5 | 344,3 | 2255,3 | 382,59 | 2236,1 | 300,29 | 2045,1 | 269,8 |

Inicialmente o que pode ser destacado foram os valores de média do atributo ‘1’ (média de níveis de cinza do histograma), que ao contrário das imagens em filme, não aumentam com o aumento de densidade mamária. Nas imagens digitais testadas, detectou que a média de níveis de intensidade decresce quanto mais densa é a mama. Isso pode ser pelo explicado pelo fato de que com os atuais sistemas FFDM de mamógrafos, cada fabricante possui um algoritmo de pós-processamento próprio para ajuste da faixa dinâmica, além de uma função de janelamento de contraste, variando assim os níveis de cinza da imagem (MOUSA *et al.*, 2014).

O gráfico da Figura 6.3 foi construído para uma melhor visualização dos valores médios obtidos na extração dos atributos de intensidade das imagens digitais. Para que o atributo ‘8’ (número de pixels acima do pico) se enquadrasse na mesma escala dos demais atributos, seu valor de média foi dividido por 1000.

Figura 6.3 – Gráfico da média dos atributos extraídos do histograma por classe de densidade mamária para as imagens digitais.



A fim de verificar o grau de dispersão dos dados, foi feito também o cálculo do coeficiente de variação (CV) dos atributos extraídos do histograma (Tabela 6.6) para as imagens digitais, com base nos valores de média aritmética e média dos desvios padrão dos atributos por classe.

Tabela 6.6 – Coeficiente de variação (porcentagem) dos atributos extraídos do histograma para as imagens digitais.

| Atributos extraídos do histograma | Padrão 1 | Padrão 2 | Padrão 3 | Padrão 4 |
|--|----------|----------|----------|----------|
| 1. Média de níveis de cinza | 2,45 | 3,94 | 3,03 | 4,80 |
| 2. Maior pico do histograma | 2,67 | 6,40 | 9,56 | 8,29 |
| 3. Menor intensidade | 88,15 | 79,66 | 55,83 | 42,64 |
| 4. Maior intensidade | 10,00 | 11,36 | 10,30 | 10,46 |
| 5. Diferença da média para a menor intensidade | 14,41 | 15,04 | 10,50 | 9,56 |
| 6. Diferença da média para a maior intensidade | 24,57 | 28,12 | 24,74 | 27,79 |
| 7. Porcentagem da maior intensidade em relação à intensidade máx. possível | 10,00 | 11,36 | 10,29 | 10,30 |
| 8. N° de pixels acima do pico | 29,73 | 34,73 | 40,22 | 54,30 |
| 9. Gradiente | 15,04 | 16,96 | 13,43 | 13,20 |

Ao contrário do desvio padrão que é uma medida de dispersão absoluta, o CV é uma medida relativa de variabilidade, podendo indicar quais atributos apresentam um conjunto de dados menos heterogêneo, com menor dispersão entre a mesma classe (padrão). Pela Tabela 6.6 observa-se que os atributos ‘1’ (média de níveis de cinza) e ‘2’ (maior pico do histograma) foram os que apresentaram menor valor de CV, enquanto que o CV calculado para o atributo ‘3’ (menor intensidade) indicou uma alta variabilidade dos dados para esse atributo.

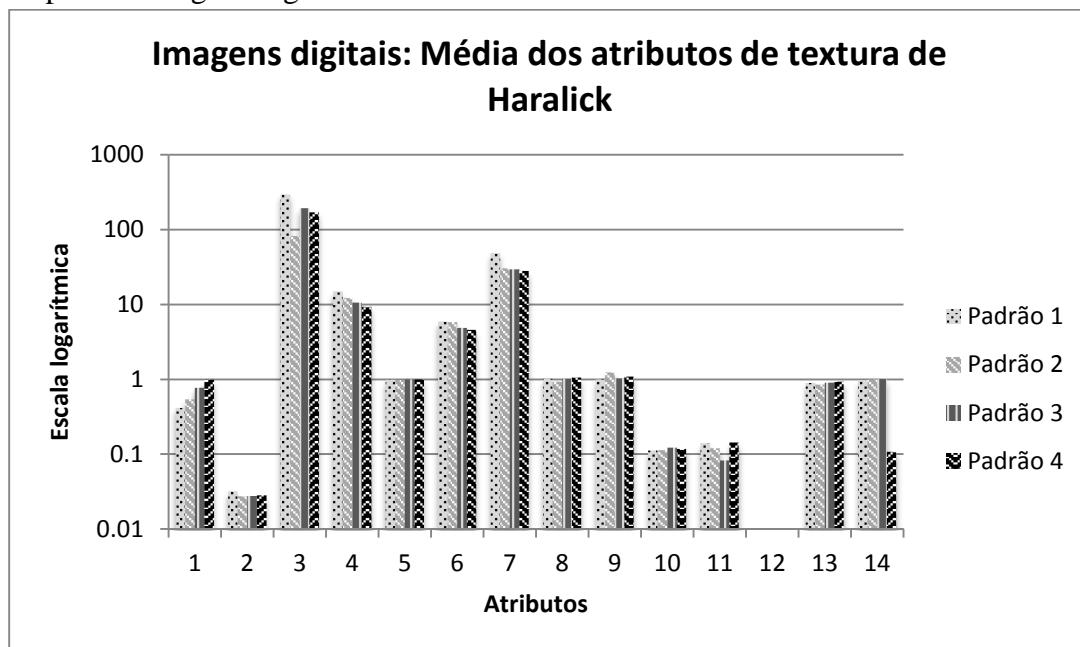
Depois dos atributos extraídos do histograma, realizou a extração dos descritores de textura de Haralick das imagens digitais, calculando a média aritmética destes atributos e a média dos desvios padrão de cada um deles, para as quatro classes de densidade mamária. A Tabela 6.7 mostra esses resultados.

Tabela 6.7 – Média aritmética e média dos desvios padrão dos atributos de textura de Haralick para as imagens digitais.

| Atributos de textura de Haralick | Padrão 1 | | Padrão 2 | | Padrão 3 | | Padrão 4 | |
|--|-----------|----------|-----------|----------|-----------|----------|-----------|----------|
| | \bar{X} | σ | \bar{X} | σ | \bar{X} | σ | \bar{X} | σ |
| 1. Uniformidade | 0,4156 | 0,0435 | 0,5383 | 0,1186 | 0,7716 | 0,1287 | 0,9847 | 0,0477 |
| 2. Contraste | 0,0321 | 0,0893 | 0,0275 | 0,0867 | 0,0278 | 0,0915 | 0,0281 | 0,0784 |
| 3. Correlação | 295,1 | 33,70 | 81,75 | 24,14 | 192,66 | 37,6933 | 168,875 | 20,341 |
| 4. Variância | 14,9064 | 0,9266 | 12,109 | 1,6121 | 10,5805 | 1,2695 | 9,2702 | 0,2676 |
| 5. Momento da diferença inversa | 0,9885 | 1,0243 | 0,9809 | 1,1027 | 0,998 | 1,0305 | 0,9926 | 1,1536 |
| 6. Média da soma | 5,9147 | 0,8773 | 5,7937 | 0,6628 | 4,8785 | 1,0711 | 4,5778 | 1,05 |
| 7. Variância da soma | 48,6999 | 13,74 | 30,2439 | 15,629 | 29,3405 | 14,1878 | 27,9684 | 13,92 |
| 8. Entropia da soma | 1,0172 | 0,0835 | 0,9304 | 0,0993 | 1,0198 | 1,0166 | 1,0609 | 1,0261 |
| 9. Entropia | 1,0004 | 0,9872 | 1,2367 | 0,9864 | 1,0296 | 0,9751 | 1,0844 | 0,9451 |
| 10. Variância da diferença | 0,1123 | 0,0233 | 0,1133 | 0,0174 | 0,1223 | 0,0923 | 0,1177 | 0,1306 |
| 11. Entropia da diferença | 0,1411 | 0,0942 | 0,1201 | 0,0783 | 0,0826 | 0,9836 | 0,1429 | 0,0876 |
| 12. Infº de correlação 1 | -0,8879 | 0,6966 | -0,8638 | 0,7375 | -0,9277 | 1,0877 | -0,8652 | 0,5188 |
| 13. Infº de correlação 2 | 0,8973 | 0,7271 | 0,8476 | 0,7707 | 0,9057 | 0,9119 | 0,9255 | 0,8319 |
| 14. Máx. coef. correlação | 0,9733 | 0,7515 | 0,9927 | 0,8314 | 1,0024 | 0,8209 | 0,1081 | 0,0974 |

A Figura 6.4 representa o gráfico dos valores de média aritmética de cada atributo, calculados na Tabela 6.7. Este gráfico foi construído a partir da escala logarítmica, reduzindo a representação a uma escala mais fácil de ser visualizada, devido à variedade de ordens de grandeza dos valores de média obtidos pelos atributos.

Figura 6.4 – Gráfico da média dos descritores de textura por classe de densidade mamária para as imagens digitais.



Para estas imagens digitais, quanto maior a densidade mamária, maior o valor obtido para o atributo ‘1’ (uniformidade). Isso significa que quanto maior a presença de tecido fibroglandular, mais heterogênea é a textura, ao contrário de imagens do padrão 1, por exemplo, que apresentam texturas mais homogêneas, com valor de uniformidade menor.

Em mamas mais densas a textura possui menor contraste, o que pode ser explicado pelos valores de média obtidos para o atributo ‘2’ (contraste). O valor de contraste decresceu à medida que aumentou o padrão de densidade da mama, comprovando o menor contraste em textura de mamas mais densas.

Assim como para os outros casos, foi calculado também o coeficiente de variação dos atributos de textura das imagens digitais, mostrados na Tabela 6.8. Para o atributo ‘12’, o cálculo foi feito a partir do módulo.

Tabela 6.8 – Coeficiente de variação (porcentagem) dos atributos de textura para as imagens digitais.

| Atributos de textura de Haralick | Padrão 1 | Padrão 2 | Padrão 3 | Padrão 4 |
|----------------------------------|----------|----------|----------|----------|
| 1. Uniformidade | 10,47 | 22,03 | 16,68 | 4,84 |
| 2. Contraste | 278,19 | 315,27 | 329,13 | 279,00 |
| 3. Correlação | 11,42 | 29,53 | 19,56 | 12,05 |
| 4. Variância | 6,22 | 13,31 | 12,00 | 2,89 |

| | | | | |
|--|--------|--------|---------|--------|
| 5. Momento da diferença inversa | 103,62 | 112,42 | 103,26 | 116,22 |
| 6. Média da soma | 14,83 | 11,44 | 21,96 | 22,94 |
| 7. Variância da soma | 28,21 | 51,68 | 48,36 | 49,77 |
| 8. Entropia da soma | 8,21 | 10,67 | 99,69 | 96,72 |
| 9. Entropia | 98,68 | 79,76 | 94,71 | 87,15 |
| 10. Variância da diferença | 20,75 | 15,36 | 75,47 | 110,96 |
| 11. Entropia da diferença | 66,76 | 65,20 | 1190,80 | 61,30 |
| 12. Infº de correlação 1* | 78,45 | 85,38 | 117,25 | 59,96 |
| 13. Infº de correlação 2 | 81,03 | 90,93 | 100,68 | 89,89 |
| 14. Máx. coef. correlação | 77,21 | 83,75 | 81,89 | 90,11 |

* Foi calculado a partir do módulo do atributo.

A Tabela 6.8 indica uma alta variabilidade entre os dados, sendo os atributos ‘1’ (uniformidade) e ‘4’ (variância) aqueles em que apresentaram uma menor dispersão entre os dados dentro da mesma classe.

6.4 Resultado da seleção dos atributos das imagens digitais

A seleção de atributos das imagens digitais foi feita a partir da técnica de agrupamento *k-means*. Todos os atributos foram testados individualmente, com o número de *clusters* do *k-means* igual a quatro, e, a partir dos melhores resultados individuais, foi feita uma combinação de dois ou mais atributos a fim de verificar a taxa de acerto da técnica com os atributos combinados. Quanto maior a taxa de acerto do *k-means*, melhor aquele atributo ou conjunto de atributos foi no agrupamento das imagens nas quatro classes, podendo então ser usado na rede neural para a classificação das imagens.

Primeiramente estão mostrados os resultados individuais do *k-means* para os atributos extraídos do histograma e depois, para os atributos de textura, conforme apresentado pelas Tabelas 6.9 e 6.10. Os dados estão ordenados por taxa de acerto.

Tabela 6.9 – Porcentagem de acerto individual dos atributos extraídos do histograma e da combinação de todos eles.

| Atributos de intensidade | Porcentagem de acerto |
|---|-----------------------|
| Menor intensidade do histograma | 25,40% |
| Porcentagem da maior intensidade em relação à intensidade máxima possível | 27,68% |
| Número de pixels acima do pico | 31,92% |

| | |
|--|--------|
| Todos os nove atributos extraídos do histograma | 33% |
| Diferença da média para a maior intensidade | 33,87% |
| Maior intensidade do histograma | 44,3% |
| Gradiente | 57% |
| Diferença da média para a menor intensidade (DMMI) | 57,98% |
| Maior pico do histograma | 63,19% |
| Média de níveis de cinza do histograma | 65,46% |

Pela Tabela 6.9 verifica que os atributos ‘maior pico do histograma’ e ‘média de níveis de cinza do histograma’ foram os que obtiveram melhores resultados, conseguindo agrupar 63,19% e 65,46% das imagens corretamente em seu padrão de densidade mamária, respectivamente.

Tabela 6.10 – Porcentagem de acerto individual dos atributos de textura de Haralick e da combinação de todos eles.

| Atributos de textura | Porcentagem de acerto |
|--|-----------------------|
| Momento da diferença inversa | 53,74% |
| Variância da soma | 55,7% |
| Entropia da soma | 56,67% |
| Variância da diferença | 59,6% |
| Entropia da diferença | 60,26% |
| Entropia | 61,23% |
| Todos os 14 atributos de textura de Haralick | 61,89% |
| Medida de infº de correlação 1 | 63,51% |
| Contraste | 64,49% |
| Máximo coeficiente de correlação | 64,82% |
| Medida de infº de correlação 2 | 65,14% |
| Média da soma | 66,1% |
| Correlação | 67,42% |
| Variância (Homogeneidade) | 67,75% |
| Uniformidade (Energia) | 75,57% |

Os resultados apresentados na Tabela 6.10 indicam que os descritores de textura de Haralick se mostraram melhores atributos, se comparados com os atributos extraídos do histograma. O atributo ‘variância’ separou corretamente 67,75% das 307 imagens, enquanto que o atributo ‘uniformidade’, acertou a classificação de 232 das 307 imagens.

A partir dos resultados das Tabelas 6.9 e 6.10 acima, foi proposto combinar alguns atributos, a fim de verificar a taxa de acerto com o *k-means* dessa combinação. A Tabela 6.11

indica os melhores resultados obtidos com a combinação de alguns atributos (acima de 65% de taxa de acerto). Nesta tabela, os atributos em negrito representam atributos extraídos do histograma, enquanto que atributos em itálico, atributos de textura de Haralick.

Tabela 6.11 – Porcentagem de acerto da combinação de alguns atributos.

| Atributos combinados | Porcentagem de acerto |
|---|-----------------------|
| <i>Atributos de Haralick > 60%:</i> <i>Entropia da diferença, Entropia, Medida infº de correl. 1 e 2, Contraste, Máx. coef. de correl., Média da soma, Correlação, Variância e Uniformidade</i> | 65,73% |
| <i>Uniformidade, Variância, Correlação, Média da Soma, Média de níveis de cinza, Maior pico, Gradiente</i> | 77,52% |
| <i>Uniformidade, Variância, Correlação e Média da Soma</i> | 79,8% |
| <i>Uniformidade, Variância, Correlação, Média da Soma, Média de níveis de cinza, Maior pico, DMMI e Gradiente</i> | 79,8% |
| <i>Uniformidade, Variância, Correlação, Média da Soma e Média de níveis de cinza</i> | 80,13% |
| <i>Uniformidade, Variância, Correlação, Média da Soma, Média de níveis de cinza e Maior pico</i> | 80,8% |
| <i>Uniformidade e Variância</i> | 82,08% |

Diante destes resultados obtidos para a seleção de atributos, julgou ser necessário escolher grupos de atributos a serem utilizados como entrada na Rede Neural Artificial proposta para a classificação. Dessa forma, na Tabela 6.12 são apresentados os cinco conjuntos de atributos que serão usados na RNA, como dado de entrada, com suas respectivas porcentagens de acerto obtidas pela técnica *k-means*.

Tabela 6.12 – Grupo de atributos selecionados para serem usados como entrada para a Rede Neural Artificial.

| Conjunto | Atributos selecionados | Porcentagem de acerto |
|----------|---|-----------------------|
| 1 | Todos os 9 atributos de intensidade | 33% |
| 2 | <i>Todos os 14 atributos de Haralick</i> | 61,89% |
| 3 | <i>Entropia da diferença, Entropia, Medida infº de correl. 1 e 2, Contraste, Máx. coef. de correl., Média da soma, Correlação, Variância e Uniformidade</i> | 65,73% |
| 4 | <i>Uniformidade, Variância, Correlação, Média da Soma, Média de níveis de cinza, Maior pico do histograma, Gradiente, DMMI</i> | 79,8% |
| 5 | <i>Uniformidade, Variância, Correlação, Média da Soma, Média de níveis de cinza e Maior pico do histograma</i> | 80,8% |

Capítulo 7 RESULTADOS E DISCUSSÕES

Neste Capítulo 7 são apresentados os resultados obtidos para a classificação das imagens dos dois testes realizados. No primeiro teste, a técnica de classificação proposta foi o *k-means*, para imagens em filme, enquanto que em um segundo momento, foi feita a classificação de imagens digitais a partir de Redes Neurais Artificiais.

7.1 Classificação das imagens em filme

Inicialmente os atributos extraídos do histograma selecionados, com curvas gaussianas, para as imagens em filme, foram inseridos individualmente na técnica *k-means* e depois combinados entre eles. Na Tabela 7.1 são apresentadas as taxas de acerto da classificação quando utilizou os atributos individuais, assim como a combinação deles no *k-means*.

Tabela 7.1 – Atributos extraídos do histograma: porcentagem de acerto e número de erros a partir da técnica de classificação *k-means*.

| Atributos | Porcentagem de acerto da classificação | Número de erros |
|--|--|-----------------|
| Maior intensidade do histograma | 85,3% | 11 |
| Maior pico do histograma/Maior intensidade do histograma | 89,3% | 8 |
| Média de níveis de cinza/Maior intensidade do histograma | 92% | 6 |
| Maior pico do histograma | 92% | 6 |
| Média de níveis de cinza/Maior pico do histograma/Maior intensidade do histograma | 93,3% | 5 |
| Média de níveis de cinza | 94,6% | 4 |
| Média de níveis de cinza/Maior pico do histograma | 96% | 3 |

O melhor resultado obtido foi de 96% de taxa de acerto. Isso significa dizer que das 75 imagens usadas na classificação, 72 delas foram classificadas corretamente pela técnica *k-means*. Os três erros desta classificação foram cometidos pela classificação equivocada de três imagens em classe densa, quando na verdade sua classe original era gordurosa-glandular. Este

resultado foi obtido quando os atributos média de níveis de cinza e maior pico do histograma foram usados simultaneamente como dado de entrada do classificador.

Após a classificação com os atributos extraídos do histograma, foram inseridos os descritores de textura de Haralick, selecionados pelas curvas gaussianas. Os resultados são mostrados na Tabela 7.2, apresentando apenas os atributos de textura e combinações desses atributos que obtiveram taxas de acerto da classificação superiores a 65%.

Tabela 7.2 – Atributos de textura: porcentagem de acerto e número de erros a partir da técnica de classificação *k-means*.

| Atributos | Porcentagem de acerto da classificação | Número de erros |
|--|--|-----------------|
| Contraste | 65,3% | 26 |
| Uniformidade/Contraste | 68% | 24 |
| Uniformidade | 69,3% | 23 |
| Correlação/Contraste | 69,3% | 23 |
| Correlação | 72% | 21 |
| Uniformidade/Correlação/Contraste | 74,6% | 19 |
| Uniformidade/Correlação | 76% | 18 |

Para os atributos de textura de Haralick, o melhor resultado foi gerado com a combinação dos atributos uniformidade e correlação. A técnica *k-means* conseguiu agrupar corretamente 76% das 75 imagens, confundindo a classe de 18 mamogramas.

Diante destes resultados, é possível verificar a superioridade dos atributos extraídos do histograma frente aos atributos de textura de Haralick na classificação das imagens em filme. Isto evidencia o fato de que imagens em filme são melhores discriminadas em nível de intensidade de pixel, possuindo maior contraste entre os diferentes tecidos presentes na mama, pois quanto maior o valor de intensidade de pixel, maior a quantidade de tecido fibroglandular presente na imagem.

Para os dois tipos de atributos, intensidade e textura, os melhores resultados foram alcançados quando mais de um atributo foi usado simultaneamente na técnica de classificação.

Conforme esperado, aqueles atributos selecionados em que visualmente tiveram curvas gaussianas mais sobrepostas, foram os que obtiveram menor porcentagem de acerto na classificação, como foi o caso dos atributos: maior intensidade do histograma e contraste.

7.2 Classificação das imagens digitais

A partir da seleção de atributos, cinco conjuntos de atributos foram escolhidos para serem testados na Rede Neural Artificial, sendo eles:

- RNA 1: todos os nove atributos extraídos do histograma;
- RNA 2: todos os 14 atributos de textura de Haralick;
- RNA 3: entropia da diferença, entropia, medida de informação de correlação 1 e 2, contraste, máximo coeficiente de correlação, média da soma, correlação, variância e uniformidade;
- RNA 4: uniformidade, variância, correlação, média da soma, média de níveis de cinza, maior pico do histograma, gradiente e diferença da média pra menor intensidade;
- RNA 5: uniformidade, variância, correlação, média da soma, média de níveis de cinza e maior pico do histograma.

Como já descrito no Capítulo 5, os seguintes parâmetros foram alterados ao longo dos testes da Rede Neural Artificial, até se obter os melhores resultados, sendo eles:

- Camada de entrada: número de neurônios igual ao número de atributos inseridos na rede;
- Camada intermediária: variou de uma a três vezes o número de atributos da camada de entrada;
- Camada de saída: dois neurônios de saída, classificando em quatro classes possíveis;
- Funções de transferência: *Linear*, *Tansig*, ou *Logsig*.
- Número de épocas: variou de 100.000 a 200.000;
- *Validation checks*: variou de 10.000 a 100.000;
- Gradiente mínimo: 10^{-6} ;

Para cada configuração, as redes foram treinadas e testadas 250 vezes, com diferentes variações do número de épocas e *validation checks* utilizados. Como foram usadas três diferentes funções de ativação, foram geradas então, 750 redes para treinamento e teste de uma mesma configuração. Por fim, o total de redes treinadas e testadas dependia do número de neurônios que foram variados na camada intermediária. No caso da RNA 1, por exemplo, em que o número de neurônios da camada intermediária variou de 9 a 27 (19 vezes), o número total de redes treinadas e testadas, neste caso, foi de 14250 redes.

Desta forma, são apresentadas as melhores porcentagens de acerto (teste de uso – 135 imagens do Grupo Teste) para cada uma das cinco RNAs testadas, com o respectivo número de neurônios utilizados em cada camada, bem como qual função de ativação foi obtido tal resultado.

Para o melhor resultado obtido (em negrito nas tabelas) é mostrada a quantidade de erros de classificação e as inversões de classes cometidas durante este teste. A função linear não apresentou bom resultado para nenhuma das configurações testadas.

A Tabela 7.3 apresenta os resultados obtidos para a RNA 1.

Tabela 7.3 – RNA 1: parâmetros utilizados e o melhor resultado (porcentagem de acerto) obtido para essa configuração.

| RNA 1 | Neurônios | Função de ativação | % Acerto |
|-------------------|----------------|----------------------|---------------|
| Neurônios entrada | Intermediários | | Teste de uso |
| 9 | 9 | <i>Tansig</i> | 52,59% |
| 9 | 12 | <i>Logsig</i> | 67,4% |
| 9 | 15 | <i>Logsig</i> | 77,03% |
| 9 | 18 | <i>Logsig</i> | 67,4% |
| 9 | 21 | <i>Logsig</i> | 74,07% |
| 9 | 24 | <i>Tansig</i> | 65,92% |
| 9 | 27 | <i>Logsig</i> | 57,78% |

A Tabela 7.3 mostra que o melhor resultado foi obtido utilizando 15 neurônios na camada intermediária, com 77,03% de acerto, correspondendo a 31 erros de classificação. Para tal, foram necessárias 200.000 épocas e 90.000 *validation checks*. A Tabela 7.4 mostra o número de erros e entre quais classes estes erros ocorreram.

Na Tabela 7.4 são apresentadas as quantidades de erros cometidos pela rede de melhor configuração, e entre quais padrões as inversões ocorreram.

Tabela 7.4 – RNA 1: número de inversões da classificação das imagens em padrões de densidade cometidas pela configuração de melhor resultado da rede.

| RNA 1 | Número |
|---|----------|
| Inversões | de erros |
| Padrão de origem→Padrão classificado | |
| Padrão 1→2 | 9 |
| Padrão 2→1 | 4 |
| Padrão 2→3 | 8 |

| | |
|-----------------------|----|
| Padrão 3→2 | 2 |
| Padrão 3→4 | 1 |
| Padrão 4→3 | 2 |
| Padrão 1→3 | 3 |
| Padrão 2→4 | 1 |
| Padrão 1→4 | 1 |
| Total de erros | 31 |

A Tabela 7.4 indica que dos 31 erros cometidos pela RNA 1, nove deles foram ocasionados pela classificação incorreta de imagens em padrão 2 de densidade mamária, sendo que seu padrão de origem era padrão 1. Já para a RNA 2, para se obter o melhor resultado, foram treinadas e testadas 21750 redes.

A Tabela 7.5 mostra os resultados para a RNA 2, quando foram utilizados os 14 atributos de textura de Haralick na camada de entrada.

Tabela 7.5 – RNA 2: parâmetros utilizados e o melhor resultado (porcentagem de acerto) obtido para essa configuração.

| RNA 2 Neurônios entrada | Neurônios Intermediários | Função de ativação | % Acerto |
|-------------------------------|-----------------------------|----------------------|---------------|
| | | | Teste de uso |
| 14 | 14 | <i>Tansig</i> | 85,18% |
| 14 | 21 | <i>Logsig</i> | 93,33% |
| 14 | 28 | <i>Logsig</i> | 85,92% |
| 14 | 35 | <i>Tansig</i> | 86,66% |
| 14 | 42 | <i>Logsig</i> | 80% |

O melhor resultado da RNA 2 foi de 93,33% de taxa de acerto, apresentando erro de 9 imagens classificadas em padrão errado, usando a função de ativação ‘*logsig*’. Este resultado foi obtido com 190.000 épocas, 85.000 *validation checks* e 21 neurônios na camada intermediária.

Os erros cometidos pela RNA 2 de melhor configuração é mostrada na Tabela 7.6.

Tabela 7.6 – RNA 2: número de inversões da classificação das imagens em padrões de densidade cometidas pela configuração de melhor resultado da rede.

| RNA 2 Inversões | Número de erros |
|---|--------------------|
| Padrão de origem → Padrão classificado | |
| Padrão 1 → 2 | 2 |
| Padrão 2 → 3 | 1 |
| Padrão 3 → 2 | 3 |
| Padrão 4 → 3 | 2 |
| Padrão 1 → 3 | 1 |
| Total de erros | 9 |

Dos nove erros de classificação da RNA 2, 3 destes erros foram cometidos pela classificação incorreta de imagens de padrão 3 em padrão 2, conforme apresentado na Tabela 7.6. A maioria dos erros (4) ocorreu na confusão entre imagens do padrão 2 em 3 ou vice-versa, devido ao fato da maior similaridade entre imagens destes padrões intermediários.

Para a RNA 3 foram treinadas e testadas 15750 redes. Os melhores resultados obtidos para esta rede, quando utilizados dez descritores de textura de Haralick, são apresentados na Tabela 7.7.

Tabela 7.7 – RNA 3: parâmetros utilizados e o melhor resultado (porcentagem de acerto) obtido para essa configuração.

| RNA 3 Neurônios Entrada | Neurônios Intermediários | Função de ativação | % Acerto Teste de uso |
|-------------------------------|-----------------------------|----------------------|--------------------------|
| 10 | 10 | <i>Logsig</i> | 85,18% |
| 10 | 16 | <i>Logsig</i> | 95,55% |
| 10 | 20 | <i>Logsig</i> | 85,92% |
| 10 | 25 | <i>Tansig</i> | 82,96% |
| 10 | 30 | <i>Logsig</i> | 80,74% |

Nesta RNA, 95,55% das imagens, ou seja, 129 das 135 imagens usadas para teste foram classificadas corretamente, utilizando 16 neurônios na camada intermediária e a função ‘*logsig*’. Foram utilizadas 150.000 épocas e 70.000 *validation checks* para se obter tal resultado. A Tabela 7.8 apresenta as inversões de classificação e o número de erros da RNA 3.

Tabela 7.8 – RNA 3: número de inversões da classificação das imagens em padrões de densidade cometidas pela configuração de melhor resultado da rede.

| RNA 3 Inversões | Número de erros |
|---|--------------------|
| Padrão de origem → Padrão classificado | |
| Padrão 1 → 2 | 1 |
| Padrão 3 → 2 | 4 |
| Padrão 3 → 4 | 1 |
| Total de erros | 6 |

Na Tabela 7.8 são mostrados os erros de classificação cometidos pela RNA 3, na qual quatro dos seis erros foram da classificação equivocada de imagens padrão 3 em imagens de padrão 2.

Os melhores resultados obtidos das 12750 redes treinadas e testadas para a RNA 4 são mostrados na Tabela 7.9, na qual havia a combinação de atributos extraídos do histograma e descritores de textura de Haralick na entrada da rede.

Tabela 7.9 – RNA 4: parâmetros utilizados e o melhor resultado (porcentagem de acerto) obtido para essa configuração.

| RNA 4 Neurônios entraida | Neurônios Intermediários | Função de ativação | % Acerto Teste de uso |
|--------------------------------|-----------------------------|----------------------|--------------------------|
| 8 | 8 | <i>Logsig</i> | 88,14% |
| 8 | 12 | <i>Logsig</i> | 94,81% |
| 8 | 14 | <i>Logsig</i> | 97,78% |
| 8 | 16 | <i>Logsig</i> | 90,37% |
| 8 | 20 | <i>Logsig</i> | 88,14% |
| 8 | 24 | <i>Tansig</i> | 82,22% |

Das 135 imagens utilizadas para teste após o treinamento, 132 delas (97,78%) foram classificadas corretamente em seu padrão de densidade mamária. Destes três erros, dois deles foram na classificação incorreta de imagens padrão 2 em padrão 3, e um erro quando a rede classificou uma imagem do padrão 4 em padrão 3, equivocadamente.

Foram necessárias 150.000 épocas, 20.000 *validation checks* para este resultado, sendo que o número de neurônios da camada intermediária para o melhor resultado foi igual a 14, também com a função de ativação ‘*logsig*’.

Por fim, a Tabela 7.10 apresenta os resultados do teste de uso da RNA 5, na qual seis descritores de textura foram utilizados como entrada da rede.

Tabela 7.10 – RNA 5: parâmetros utilizados e o melhor resultado (porcentagem de acerto) obtido para essa configuração.

| RNA 5 Neurônios entrada | Neurônios Intermediários | Função de ativação | % Acerto |
|----------------------------|-----------------------------|----------------------|---------------|
| | | | Teste de uso |
| 6 | 6 | <i>Logsig</i> | 92,59% |
| 6 | 8 | <i>Logsig</i> | 96,29% |
| 6 | 10 | <i>Logsig</i> | 99,26% |
| 6 | 12 | <i>Logsig</i> | 97,03% |
| 6 | 14 | <i>Logsig</i> | 97,78% |
| 6 | 16 | <i>Logsig</i> | 98,51% |
| 6 | 18 | <i>Logsig</i> | 91,11% |

Esta rede foi a que obteve melhor resultado, com 99,26% de taxa de acerto na classificação, confundindo a classificação de apenas uma imagem, sendo esta de padrão 3, mas classificada como padrão 4. Usando seis neurônios na camada de entrada, dez na camada intermediária, e a função ‘*logsig*’. A RNA 5 foi treinada e testada 9750 vezes, com diversas configurações, sendo o melhor resultado obtido com 150.000 épocas e 10.000 *validation checks*.

Uma vez obtidos tais resultados para cada uma das cinco Redes Neurais Artificiais, os parâmetros usados nas melhores configurações foram salvos, e as redes treinadas e testadas por mais dez vezes, a fim de se obter uma taxa de acerto médio. Assim como nos casos anteriores, ao longo destes dez testes, o conjunto de dados para treinamento e para teste foi redividido aleatoriamente.

A Tabela 7.11 apresenta esta média de taxas de acerto após os dez treinamentos, além do acerto obtido pelo *k-means* durante a seleção, o acerto do teste de uso para cada uma das cinco redes e o erro quadrático médio (EQM).

Tabela 7.11 – Resumo dos resultados.

| Testes | <i>K-means</i> | Teste de uso | Média de taxas de acerto | EQM |
|--------------|----------------|--------------|--------------------------|--------|
| RNA 1 | 33% | 77,03% | 73,40% | 0,2401 |
| RNA 2 | 61,89% | 93,33% | 91,8% | 0,0893 |
| RNA 3 | 65,73% | 95,55% | 92,9% | 0,0861 |
| RNA 4 | 79,8% | 97,78% | 97,33% | 0,0196 |
| RNA 5 | 80,8% | 99,26% | 98,95% | 0,0089 |

A partir da Tabela 7.11 fica claro que, com a utilização das Redes Neurais Artificiais, a porcentagem de acerto na classificação aumentou consideravelmente em comparação com a técnica *k-means*, mostrando a robustez das redes neurais supervisionadas frente a técnicas de agrupamento não supervisionadas.

Foi possível, então, separar imagens mamográficas em classes de densidade mamária a partir da extração de atributos, sendo esta etapa diretamente relacionada com o nível de acerto da classificação. O melhor resultado foi obtido com atributos de textura de Haralick, evidenciando que, para as imagens digitais testadas, os descritores de textura diferenciam melhor os mamogramas em comparação aos atributos extraídos do histograma.

Além dos cálculos das porcentagens de acertos para os testes de uso realizados, da quantificação dos erros, e da porcentagem de acerto médio após dez treinamentos com a melhor configuração das redes (Tabela 7.11), foi realizado o cálculo da média de erros durante os dez treinamentos para cada uma das RNAs testadas, apresentado na Tabela 7.12.

Tabela 7.12 – Média de erros por padrão durante os dez treinamentos com a melhor configuração de cada uma das cinco redes testadas.

| Testes | Padrão 1 | Padrão 2 | Padrão 3 | Padrão 4 | Total de erros |
|--------------|----------|----------|----------|----------|----------------|
| RNA 1 | 14,5 | 15,2 | 3,3 | 2,9 | 35,9 |
| RNA 2 | 1,4 | 2 | 6,2 | 1,4 | 11,0 |
| RNA 3 | 0,4 | 3 | 4,3 | 1,9 | 9,6 |
| RNA 4 | 0,5 | 1,6 | 0,9 | 0,6 | 3,6 |
| RNA 5 | 0,3 | 0,2 | 0,2 | 0,7 | 1,4 |

A Tabela 7.12 mostra que, durante os dez treinamentos e testes, ocorreram, em média, 35,9 erros para a RNA 1. Destes 35,9 erros, a maioria deles (15,2) foram erros na classificação de imagens que, originalmente, eram imagens pertencentes ao padrão 2 de densidade mamária, mas foram classificadas em outra classe. Já para a RNA 5, a rede com o

menor erro médio, durante os dez treinamentos a maioria dos erros ocorreu na classificação incorreta de imagens pertencentes ao padrão 4 de densidade mamária.

Capítulo 8 CONCLUSÕES

Além da mamografia depender de fatores fisiológicos das estruturas visualizadas e das características técnicas dos sistemas de aquisição e de armazenamento da imagem, o diagnóstico, através deste tipo de exame, é diretamente vinculado à subjetividade na interpretação das imagens. Como consequência de tal fato, a classificação de imagens mamográficas por padrão de densidade é uma tarefa com dificuldade cada vez maior, e por isso, sujeita a resultados com alto grau de confusão.

Uma das possíveis alternativas para facilitar tal caracterização de mamogramas em classes de densidade mamária é a utilização de técnicas de classificação, conforme proposto neste estudo. Desta forma, o objetivo deste trabalho foi classificar imagens mamográficas em padrões de densidade mamária, seguindo a classificação BI-RADS™, a partir de atributos extraídos do histograma e descritores de textura.

É importante destacar que o resultado dos classificadores está diretamente relacionado com a etapa de extração e seleção dos atributos. Neste caso, os padrões de densidade mamária apresentam características distintas entre elas, diferenciando-se pela variação de intensidade de pixels e/ou pela textura da imagem, permitindo assim classificar imagens com taxas de erro aceitáveis.

Foi possível verificar também a influência destes atributos extraídos do histograma e de textura nos dois tipos de imagem testados (filme x FFDM). Para as imagens de filme, os atributos extraídos do histograma mostraram-se superiores na classificação devido à notável diferença em termos de níveis de cinza dos diferentes tecidos da imagem.

Já para o outro teste, com imagens digitais de FFDM, os resultados utilizando descritores de textura foram melhores. Isso pode ser explicado pelo fato que, com os sistemas mamográficos digitais, a função de janelamento de contraste varia os níveis de cinza da imagem, o que faz com que, não necessariamente, tecido gorduroso apareça mais escuro na imagem, devido à variação de pixels produzida por essa função.

Foi proposto também investigar o método *k-means*, tanto como método de *clustering*, bem como procedimento de seleção de atributos. Com os resultados obtidos, percebeu que tal técnica se mostrou eficaz em ambas as tarefas. No teste com o conjunto de dados menor (75 imagens em filme) o *k-means* obteve 96% de taxa de acerto como classificador, e para o

segundo teste (imagens digitais), a técnica *k-means* contribuiu para a escolha dos atributos a serem usados na Rede Neural Artificial.

Com a utilização de Redes Neurais Artificiais, foi possível a partir deste trabalho, classificar imagens mamográficas em quatro padrões de densidade mamária com uma taxa de acerto de 99,26% comprovando a robustez de RNAs como método de classificação. Os melhores resultados foram obtidos com a combinação de alguns atributos, sendo a maioria deles, descritores de textura de Haralick, evidenciando as diferenças entre imagens obtidas por diferentes tecnologias.

O próximo passo do trabalho é a implementação de uma técnica de segmentação do músculo peitoral das imagens sob vista médio-lateral oblíqua. Além disso, espera-se aumentar o banco de imagens, sobretudo com imagens de padrão 4 (mama densa) de densidade mamária, de forma que novos testes sejam realizados, permitindo incluir tal proposta de classificação em um sistema de auxílio ao diagnóstico.

REFERÊNCIAS

(ABRAMOFF, MAGALHÃES, RAM, 2004)

ABRAMOFF, M. D.; MAGALHÃES, P.J.; RAM, S. J. Image processing with ImageJ. **Biophotonics international**, v. 11, n. 7, p. 36-42, 2004.

(ACR, 1998)

American College of Radiology (ACR). **Illustrated Breast Imaging Reporting and Data System (BI-RADS)**. 3rd Ed. American College of Radiology, 1998.

(ANGULO *et al.*, 2015)

ANGULO, A. et al. Experimental assessment of an automatic breast density classification algorithm based on principal component analysis applied to histogram data. In: **Tenth International Symposium on Medical Information Processing and Analysis**. International Society for Optics and Photonics, 2015.

(BAKIC *et al.*, 2009)

BAKIC, P. R. et al. Breast Percent Density: Estimation on Digital Mammograms and Central Tomosynthesis Projections1. **Radiology**, v. 252, n. 1, p. 40-49, 2009.

(BEALE, HOGAN, DEMUTH, 2015)

BEALE, M. H.; HOGAN, M. T.; DEMUTH, H. B. **Neural Network Toolbox: User's Guide**. Natick, MA: Mathworks, 2015.

(BEALE, JACKSON, 1990)

BEALE, R.; JACKSON, T. **Neural Computing-an introduction**. CRC Press, 1990.

(BOEHM *et al.*, 2008)

BOEHM, H. F. et al. Automated classification of breast parenchymal density: topologic analysis of X-ray attenuation patterns depicted with digital mammography.

American Journal of Roentgenology, v. 191, n. 6, p. W275-W282, 2008.

(BOSCH *et al.*, 2006)

BOSCH, A. et al. Modeling and classifying breast tissue density in mammograms. In: **Computer Vision and Pattern Recognition, 2006 IEEE Computer Society Conference on**. IEEE, 2006. p. 1552-1558.

(BOUKERROUI *et al.*, 1998)

BOUKERROUI, D. et al. Multiresolution texture based adaptive clustering algorithm for breast lesion segmentation. **European Journal of Ultrasound**, v. 8, n. 2, p. 135-144, 1998.

(BOVIS, SINGH, 2002)

BOVIS, K; SINGH, S. Classification of mammographic breast density using a combined classifier paradigm. In: **Medical Image Understanding and Analysis (MIUA) Conference, Portsmouth**. 2002.

(BOYD *et al.*, 1995)

BOYD, N. F. et al. Quantitative classification of mammographic densities and breast cancer risk: results from the Canadian National Breast Screening Study. **Journal of the National Cancer Institute**, v. 87, n. 9, p. 670-675, 1995.

(BOYD *et al.*, 2007)

BOYD, N. F. et al. Mammographic density and the risk and detection of breast cancer. **New England Journal of Medicine**, v. 356, n. 3, p. 227-236, 2007.

(BYNG *et al.*, 1998)

BYNG, J. W. et al. Analysis of mammographic density and breast cancer risk from digitized mammograms. **RadioGraphics**, vol. 18, n. 6, p. 1587-1598, 1998.

(CASTELLA *et al.*, 2007)

CASTELLA, C. et al. Semiautomatic mammographic parenchymal patterns classification using multiple statistical features. **Academic radiology**, v. 14, n. 12, p. 1486-1499, 2007.

(CHENG *et al.*, 2010)

CHENG, E. et al. Mammographic image classification using histogram intersection. Biomedical imaging: from nano to macro. In: **IEEE international symposium**. 2010. p. 14-17.

(CUZICK *et al.*, 2004)

CUZICK, J. et al. Tamoxifen and breast density in women at increased risk of breast cancer. **Journal of the National Cancer Institute**, v. 96, n. 8, p. 621-628, 2004.

(D'ORSI *et al.*, 2003)

D'ORSI, C. J. et al. Breast imaging reporting and data system: ACR BI-RADS-mammography. **American College of Radiology (ACR), Reston**, 2003.

(DERSHAW, 2005)

DERSHAW, D. D. Film or digital mammographic screening?. **New England Journal of Medicine**, v. 353, n. 17, p. 1846, 2005.

(DORGAN *et al.*, 2012)

DORGAN, J. F. et al. Height, adiposity and body fat distribution and breast density in young women. **Breast Cancer Res**, v. 14, n. 4, p. R107, 2012.

(DUDA, HART, STORK, 2012)

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. John Wiley & Sons, 2012.

(EBERL *et al.*, 2006)

EBERL, M. M. et al. BI-RADS Classification for Management of Abnormal Mammograms. **The Journal of the American Board of Family Medicine**, vol. 9, p. 161-164, 2006.

(FERLAY *et al.*, 2010)

FERLAY, J. et al. Global Burden of Breast Cancer. **Breast Cancer Epidemiology**, New York. Springer, p.1-19, 2010.

(FERRARI *et al.*, 2005)

FERRARI, R. J. et al. Automatic identification of the pectoral muscle in mammograms. **Medical Imaging, IEEE Transactions on**, v. 23, n. 2, p. 232-245, 2004.

(FORGEY, 1965)

FORGEY, E. W. Cluster analysis of multivariate data: efficiency versus interpretability of classifications. **Biometrics**, v. 21, p. 768-769, 1965.

(FOWLER *et al.*, 2014)

FOWLER, E. E. E. et al. Automated Percentage of Breast Density Measurements for Full-field Digital Mammography Applications. **Academic radiology**, v. 21, n. 8, p. 958-970, 2014.

(FUKUNAGA *et al.*, 1990)

FUKUNAGA, K. Introduction to statistical pattern recognition. **Ch**, v. 9, p. 401-405, 1990.

(GONZALEZ, WINTZ, 1992)

GONZALEZ, R. C.; WINTZ, P. **Digital Image Processing**. Addison-Wesley Publishing Company, United States of America, 1992.

(GONZALEZ, 2009)

GONZALEZ, R. C. **Digital image processing**. Pearson Education India, 2009.

(GONZALEZ, WOODS, 2010)

GONZALEZ, R. C.; WOODS R. E. **Processamento digital de imagens**. 3^a Ed. Pearson Prentice Hall, São Paulo, 2010.

(GRAM, FUNKHOUSER, TABÁR, 1997)

GRAM, I. T.; FUNKHOUSER, E.; TABÁR, L. The Tabar classification of mammographic parenchymal patterns. **European journal of radiology**, v. 24, n. 2, p. 131-136, 1997.

(HARALICK, SHANMUGAM, DINSTEIN, 1973)

HARALICK, R. M.; SHANMUGAM, K.; DINSTEIN, I. H. Textural features for image classification. **Systems, Man and Cybernetics.**, n. 6, p. 610-621, 1973.

(HARALICK, 1979)

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

(HARTIGAN, WONG, 1979)

HARTIGAN, J. A.; WONG, M. A. Algorithm AS 136: A k-means clustering algorithm. **Applied statistics**, p. 100-108, 1979.

(HAUS, YAFFE, 2000)

HAUS, A. G.; YAFFE, M. J. Screen-film and digital mammography: image quality and radiation dose considerations. **Radiologic Clinics of North America**, v. 38, n. 4, p. 871-898, 2000.

(HAYKIN, 1994)

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. New York: Macmillan College Publishing Company, 1994.

(HERTZ, KROGH, PALMER, 1991)

HERTZ, J.; KROGH, A.; PALMER, R. G. **Introduction to the theory of neural computation**. Basic Books, 1991.

(HIGHNAM *et al.*, 2010)

HIGHNAM, R. et al. Robust breast composition measurement-VolparaTM. In: **Digital Mammography**. Springer Berlin Heidelberg, 2010. p. 342-349.

(HONG *et al.*, 2005)

HONG, Andrea S. et al. BI-RADS for sonography: positive and negative predictive values of sonographic features. **American Journal of Roentgenology**, v. 184, n. 4, p. 1260-1265, 2005.

(HUBER, DUTRA, 1998)

HUBER, R.; DUTRA, L. V. Feature selection for ERS-1/2 InSAR classification: high dimensionality case. In: **Geoscience and Remote Sensing Symposium Proceedings, 1998. IGARSS'98. 1998 IEEE International**. IEEE, 1998. p. 1605-1607.

(INCA, 2014)

INSTITUTO NACIONAL DE CÂNCER JOSÉ ALENCAR GOMES DA SILVA, **Estimativa 2014: Incidência de Câncer no Brasil**. Rio de Janeiro, 2014.

(JACKSON *et al.*, 1993)

JACKSON, V. P. et al. Imaging of the radiographically dense breast. **Radiology**, v. 188, n. 2, p. 297-301, 1993.

(KALLENBERG *et al.*, 2011)

KALLENBERG, M. G. J. et al. Automatic breast density segmentation: an integration of different approaches. **Physics in medicine and biology**, v. 56, n. 9, p. 2715, 2011.

(KARSSEMEIJER, 1998)

KARSSEMEIJER, N. Automated classification of parenchymal patterns in mammograms. **Physics in medicine and biology**, v. 43, n. 2, p. 365, 1998.

(KATO *et al.*, 1995)

KATO, I. et al. A nested case-control study of mammographic patterns, breast volume, and breast cancer (New York City, NY, United States). **Cancer Causes & Control**, v. 6, n. 5, p. 431-438, 1995.

(KELLER *et al.*, 2012)

KELLER, B. M. et al. Estimation of breast percent density in raw and processed full field digital mammography images via adaptive fuzzy c-means clustering and support vector machine segmentation. **Medical physics**, v. 39, n. 8, p. 4903-4917, 2012.

(KELLER *et al.*, 2013)

KELLER, B. M. et al. Reader variability in breast density estimation from full-field digital mammograms: the effect of image postprocessing on relative and absolute measures. **Academic radiology**, v. 20, n. 5, p. 560-568, 2013.

(KOPANS, 2000)

KOPANS, D. B. **Imagen da Mama**, 2^a edição, Revinter, 2000. 852pp.

(KOVÁCS, 2002)

KOVÁCS, Z. L. **Redes neurais artificiais**. Editora Livraria da Física, 2002.

(LIU *et al.*, 2011)

LIU, Q. et al. Mammogram density estimation using sub-region classification. In: **Biomedical Engineering and Informatics (BMEI), 2011 4th International Conference on**. IEEE, 2011. p. 356-359.

(MANDUCA *et al.*, 2009)

MANDUCA, A. et al. Texture features from mammographic images and risk of breast cancer. **Cancer Epidemiology Biomarkers & Prevention**, v. 18, n. 3, p. 837-845, 2009.

(MARQUES FILHO, VIEIRA NETO, 1999)

MARQUES FILHO, Ogê; VIEIRA NETO, H. **Processamento digital de imagens**. Brasport, 1999.

(MASCARENHAS, VELASCO, 1989)

MASCARENHAS, N. D. A.; VELASCO, F. R. D. **Processamento Digital de Imagens**. IV EBAI-Escola Brasileiro-Argentina de Informática. Kapeluz, Buenos Aires, Argentina, 1989.

(MASTERS, 1994)

MASTERS, T. **Signal and Image Processing with Neural Networks a C++**. New York: John Wiley & Sons, 1994.

(McCORMACK, SILVA, 2006)

McCORMACK, V. A.; SILVA, I. S. Breast density and parenchymal patterns as markers of breast cancer risk: a meta-analysis. **Cancer Epidemiology Biomarkers & Prevention**, v. 15, n. 6, p. 1159-1169, 2006.

(MILLER, ASTLEY, 1992)

MILLER, P.; ASTLEY, S. Classification of breast tissue by texture analysis. **Image and Vision Computing**, v. 10, n. 5, p. 277-282, 1992.

(MITCHELL, BASSETT, 1988)

MITCHELL JR, G. W.; BASSETT, L. W. Mastologia prática. **Mastologia prática**, 1988.

(MOREIRA *et al.*, 2012)

MOREIRA, I. C. et al. INbreast: toward a full-field digital mammographic database. **Academic Radiology**, v. 19, n. 2, p. 236-248, 2012.

(MOUSA *et al.*, 2014)

MOUSA, D. S. et al. Mammographic density and cancer detection: does digital imaging challenge our current understanding?. **Academic Radiology**, v. 21, n. 11, p.1377-1385, 2014.

(MUSTRA, GRGIC, DELAC, 2012)

MUŠTRA, M.; GRGIĆ, M.; DELAČ, K. Breast density classification using multiple feature selection. **AUTOMATIKA: časopis za automatiku, mjerjenje, elektroniku, računarstvo i komunikacije**, v. 53, n. 4, p. 362-372, 2012.

(OLIVER *et al.*, 2008)

OLIVER, A. et al. A novel breast tissue density classification methodology. **Information Technology in Biomedicine, IEEE Transactions on**, v. 12, n. 1, p. 55-65, 2008.

(OLIVER, FREIXENET, ZWIGGELAAR, 2005)

OLIVER, A.; FREIXENET, J.; ZWIGGELAAR, R. Automatic classification of breast density. In: **Image Processing, 2005. ICIP 2005. IEEE International Conference on**. IEEE, 2005. p. II-1258-61.

(PANDYA, MACY, 1995)

PANDYA, A.; MACY, R. **Neural Networks for pattern recognition using C++**: IEEE Press and CRC Press 1995.

(PETROUDI, KADIR, BRADY, 2003)

PETROUDI, S.; KADIR, T.; BRADY, M. Automatic classification of mammographic parenchymal patterns: A statistical approach. In: **Engineering in Medicine and Biology Society, 2003. Proceedings of the 25th Annual International Conference of the IEEE**. IEEE, 2003. p. 798-801.

(PINSKY, HELVIE, 2010)

PINSKY, R. W.; HELVIE, M. A. Mammographic breast density: effect on imaging and breast cancer risk. **Journal of the National Comprehensive Cancer Network**, v. 8, n. 10, p. 1157-1165, 2010.

(PIRES, 2007)

PIRES, S. R. **Software Gerenciador De Base De Dados E Imagens Radiológicas Para Avaliação De Monitores.** Tese de doutorado - Universidade Federal de São Paulo, 2007.

(PISANO *et al.*, 2005)

PISANO, E. D. et al. Diagnostic Performance Of Digital Versus Film Mammography For Breast-Cancer Screening. **The New England Journal of Medicine**, v. 353, p. 1773-1783, 2005.

(PISANO, YAFFE, 2005)

PISANO, E. D.; YAFFE, M. J. Digital Mammography 1. **Radiology**, v. 234, n. 2, p.353-362, 2005.

(POULOS *et al.*, 2003)

POULOS, A. et al. Breast compression in mammography: how much is enough?. **Australasian radiology**, v. 47, n. 2, p. 121-126, 2003.

(PRATT, 1991)

PRATT, W. K. **Digital Image Processing**. Publisher John Wiley & Sons, 1991.

(PRATT, 2001)

PRATT, W. K. **Digital Image Processing**. 3^a Ed. Publisher John Wiley & Sons, 2001.

(RIASCOS, 1999)

RIASCOS, A. Vertical mammoplasty for breast reduction. **Aesthetic plastic surgery**, v. 23, n. 3, p. 213-217, 1999.

(ROBBINS, MONRO, 1951)

ROBBINS, H.; MONRO, S. A stochastic approximation method. **The annals of mathematical statistics**, p. 400-407, 1951.

(ROBSON, KOTRE, FAULKNER, 1995)

ROBSON, K. J.; KOTRE, C. J.; FAULKNER, K. The use of a contrast-detail test object in the optimization of optical density in mammography. **The British journal of radiology**, v. 68, n. 807, p. 277-282, 1995.

(ROSE, 2005)

ROSE, C. J. **Statistical models of mammographic texture and appearance**. 2005. 314f. Tese (Doutorado em Ciências) – School of Medicine, University of Manchester, Manchester, 2005.

(ROWLANDS, 2002)

ROWLANDS, J. A. The physics of computed radiography. **Physics in medicine and biology**, v. 47, n. 23, p. R123, 2002.

(RUBIN, 1989)

RUBIN, R. H. The effect of density variations on elemental abundance ratios in gaseous nebulae. **The Astrophysical Journal Supplement Series**, v. 69, p. 897-910, 1989.

(RUMELHART, HINTON, WILLIAMS, 1986)

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

(SAFTLAS *et al.*, 1991)

SAFTLAS, A. F. et al. Mammographic densities and risk of breast cancer. **Cancer**, v. 67, n. 11, p. 2833-2838, 1991.

(SCHREER, 2009)

SCHREER, I. Dense breast tissue as an important risk factor for breast cancer and implications for early detection. **Breast Care**, v. 4, n. 2, p. 89-92, 2009.

(SENIE *et al.*, 1994)

SENIE, R. T. et al. Method Of Tumor Detection Influences Disease-Free Survival Of Women With Breast Carcinoma. **Cancer**, vol. 73, p. 1666-1672, 1994.

(SICKLES *et al.*, 2013)

SICKLES, E. A. et al. **ACR BI-RADS® Mammography**. In: **ACR BI-RADS® Atlas, Breast Imaging Reporting and Data System**. Reston, VA, American College of Radiology; 2013.

(SIEGEL *et al.*, 2015)

SIEGEL, R. L. et al. Cancer statistics. **CA: A Cancer Journal for Clinicians**, v. 65, n. 1, p. 5-29, 2015.

(SMITH, 2003)

SMITH, A. P. Fundamentals of digital mammography. **Physics, technology and practical considerations**. Disponível em: <http://www.hologic.com/oem/pdf>, 2003.

(SUBASHINI, RAMALINGAM, PALANIVEL, 2010)

SUBASHINI, T. S.; RAMALINGAM, V.; PALANIVEL, S. Automated assessment of breast tissue density in digital mammograms. **Computer Vision and Image Understanding**, v. 114, n. 1, p. 33-43, 2010.

(SUCKLING *et al.*, 1994)

SUCKLING, J. et al. The mammographic image analysis society digital mammogram database. In: **Exerpta Medica. International Congress Series**. 1994. p. 375-378.

(TABÁR, TOT, DEAN, 2005)

TABÁR, L.; TOT, T.; DEAN, P. B. **Breast Cancer: The art and science of early detection with mammography: perception, interpretation, histopathologic correlation**. 1st Ed. New York: Thieme, 2005. 484p.

(TAPLIN *et al.*, 2002)

TAPLIN, S. H. et al. Concordance of Breast Imaging Reporting and Data System Assessments and Management Recommendations in Screening Mammography 1. **Radiology**, v. 222, n. 2, p. 529-535, 2002.

(TAYLOR *et al.*, 1994)

TAYLOR, P. et al. Measuring image texture to separate “difficult” from “easy” mammograms. **The British journal of radiology**, v. 67, n. 797, p. 456-463, 1994.

(TORTAJADA *et al.*, 2012)

TORTAJADA, M. et al. Adapting breast density classification from digitized to full-field digital mammograms. In: **Breast Imaging**. Springer Berlin Heidelberg, 2012. p. 561-568.

(TROSSET, 2001)

TROSSET, M. W. **An Introduction to Statistical Inference and Data Analysis**. College of William & Mary, Williamsburg, VA 23187-8795, 2001.

(TZIKOPOULOS *et al.*, 2011)

TZIKOPOULOS, S. D. et al. A fully automated scheme for mammographic segmentation and classification based on breast density and asymmetry. **computer methods and programs in biomedicine**, v. 102, n. 1, p. 47-63, 2011.

(VACHON *et al.*, 2007)

VACHON, C. M. et al. Mammographic density, breast cancer risk and risk prediction. **Breast Cancer Res**, v. 9, n. 6, p. 217, 2007.

(VÁLLEZ *et al.*, 2014)

VÁLLEZ, N. et al. Breast density classification to reduce false positives in CADe systems. **Computer methods and programs in biomedicine**, v. 113, n. 2, p. 569-584, 2014.

(VARGHESE *et al.*, 2012)

VARGHESE, J. S. et al. Mammographic breast density and breast cancer: evidence of a shared genetic basis. **Cancer research**, v. 72, n. 6, p. 1478-1484, 2012.

(VARMA, ZISSERMAN, 2002)

VARMA, M.; ZISSERMAN, A. Classifying images of materials: Achieving viewpoint and illumination independence. In: **Computer Vision—ECCV 2002**. Springer Berlin Heidelberg, 2002. p. 255-271.

(WANG *et al.*, 2003)

WANG, X. H. et al. Automated assessment of the composition of breast tissue revealed on tissue-thickness-corrected mammography. **American Journal of Roentgenology**, v. 180, n. 1, p. 257-262, 2003.

(WANG *et al.*, 2011)

WANG, J. et al. Bag-of-features based classification of breast parenchymal tissue in the mammogram via jointly selecting and weighting visual words. In: **Image and Graphics (ICIG), 2011 Sixth International Conference on**. IEEE, 2011. p. 622-627.

(WHITMAN, HAYGOOD, 2012)

WHITMAN, G. J.; HAYGOOD, T. M. **Digital Mammography: A Practical Approach**. Cambridge University Press, 2012.

(WOLBARST, 1993)

WOLBARST, A. B. **Physics of radiology**. McGraw-Hill/Appleton & Lange, 1993.

(WOLFE, 1976)

WOLFE, J. N. Breast patterns as an index of risk for developing breast cancer. **American Journal of Roentgenology**, v. 126, n. 6, p. 1130-1137, 1976.

(YAFFE, 2008)

YAFFE, M. J. Measurement of mammographic density. **Breast Cancer Res**, v. 10, n. 3, p. 209, 2008.

(YAGHJYAN *et al.*, 2011)

YAGHJYAN, L et al. Mammographic breast density and subsequent risk of breast cancer in postmenopausal women according to tumor characteristics. **Journal of the National Cancer Institute**, v. 103, n. 15, p. 1179-1189, 2011.

(YOUNG, WALLIS, RAMSDALE, 1994)

YOUNG, K. C.; WALLIS, M. G.; RAMSDALE, M. L. Mammographic film density and detection of small breast cancers. **Clinical radiology**, v. 49, n. 7, p. 461-465, 1994.

(ZHOU *et al.*, 2001)

ZHOU, C. et al. Computerized image analysis: Estimation of breast density on mammograms. **Medical physics**, v. 28, n. 6, p. 1056-1069, 2001.