

**UNIVERSIDADE FEDERAL DE MINAS GERAIS
DEPARTAMENTO DE ENGENHARIA NUCLEAR
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS E TÉCNICAS
NUCLEARES**

**DESENVOLVIMENTO DE ALGORITMOS PARA AVALIAÇÃO DA
IMAGEM DO SIMULADOR PHANTOM MAMA PARA O CONTROLE
DE QUALIDADE EM MAMOGRAFIA**

CAROLINA MARCELA VILORIA BARRAGÁN

Belo Horizonte

2016

CAROLINA MARCELA VILORIA BARRAGÁN

**DESENVOLVIMENTO DE ALGORITMOS PARA AVALIAÇÃO DA
IMAGEM DO SIMULADOR PHANTOM MAMA PARA O CONTROLE
DE QUALIDADE EM MAMOGRAFIA.**

Tese apresentada ao Programa de Pós-Graduação em Ciências e Técnicas Nucleares, do Departamento de Engenharia Nuclear da Universidade Federal de Minas Gerais, como parte das exigências para obtenção do título de Doutor em Ciências e Técnicas Nucleares.
Área de Concentração: Ciências das Radiações.

Orientador: Prof. Dra. Maria do Socorro Nogueira Tavares.

Belo Horizonte

2016

V762d

Viloria Barragán, Carolina Marcela.

Desenvolvimento de algoritmos para avaliação da imagem do Simulador Phantom mama para o controle de qualidade em mamografia [manuscrito] / Carolina Marcela Viloria Barragán. - 2016. 79 f., enc.: il.

Orientadora: Maria do Socorro Nogueira Tavares.

Tese (doutorado) Universidade Federal de Minas Gerais, Escola de Engenharia.

Anexos: f. 71-79.

Bibliografia: f. 60-70.

1. Engenharia nuclear - Teses. 2. Mamas - Radiografia - Controle de qualidade - Teses. 3. Processamento de imagens - Técnicas digitais - Teses. I. Tavares, Maria do Socorro Nogueira. II. Universidade Federal de Minas Gerais. Escola de Engenharia. III. Título.

CDU: 621.039(043)

**Dedico esse trabalho a meus amados pais,
minhas incondicionais irmãs e irmão,
e minhas preciosas sobrinhas,
os presentes da minha vida.**



UNIVERSIDADE FEDERAL DE MINAS GERAIS

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS E TÉCNICAS NUCLEARES



FOLHA DE APROVAÇÃO

**DESENVOLVIMENTO DE ALGORITMOS PARA AVALIAÇÃO DO SIMULADOR
PHANTOM MAMA PARA O CONTROLE DE QUALIDADE EM MAMOGRAFIA**

CAROLINA MARCELA VILORIA BARRAGAN

Tese submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em CIÊNCIAS E TÉCNICAS NUCLEARES, como requisito parcial para obtenção do grau de Doutor em CIÊNCIAS E TÉCNICAS NUCLEARES, área de concentração CIÊNCIAS DAS RADIAÇÕES.

Aprovada em 13 de julho de 2016, pela banca constituída pelos membros:

Dra. Maria do Socorro Nogueira Tavares - Orientadora
PCTN - CDTN/CNEN

Prof. Tarcísio Passos Ribeiro de Campos
Departamento de Engenharia Nuclear - UFMG

Profa. Priscila do Carmo Santana
Departamento de Anatomia e Imagem - UFMG

Dr. Luiz Cláudio Meira Belo
CDTN/CNEN

Prof. João Emilio Peixoto
UFRJ

Belo Horizonte, 13 de julho de 2016.

AGRADECIMENTOS

A Deus, pela vida e por todas as oportunidades que com ela me traz.

À Professora Dra. Maria do Socorro Nogueira pela confiança, apoio e motivação durante todos esses anos no Brasil.

Ao Dr. Joao Emilio Peixoto pelas suas valiosas contribuições no desenvolvimento desse trabalho.

Aos professores Luiz Claudio Meira, Priscila do Santos Santana e Tarciso Ribeiro dos Campos por aceitarem participar da banca de defesa e pelos seus importantes aportes.

A todos os professores do Curso de Pós-graduação pelos ensinamentos, incentivo e apoio recebido, especialmente a Cláudia, Maria Auxiliadora e Antonella. Assim como a todos meus colegas e funcionários do Departamento de Engenharia Nuclear, especialmente Aline por toda a colaboração prestada, sempre dirigente.

Ao CDTN e seus funcionários, por toda infraestrutura concedida para a realização deste trabalho.

A VISA-MG, por ter me permitido aceder às imagens do Banco de dados do Programa do Monitoramento Mensal da Qualidade da Imagem, especialmente a Geórgia.

Aos meus pais, Nubia e Oswaldo, pelo seu apoio incondicional. Porque sempre estão aí para mim. Às minhas irmãs (Karina, Carol, Karen) e meu irmão (Jesus David) pelo carinho e apoio na distância. Às minhas sobrinhas, Dani, Natha e Gabi, que são o melhor presente de minhas irmãs.

As minhas amigas do Laboratório de Radioproteção aplicado a Mamografia (LARAM) que estiveram comigo ao longo destes anos sempre me ajudando e incentivando, Katiane e Danielle, e colegas com quem tenho compartilhado tanto como: Lucas, Fernando, Sabrina, Bruno, Jessica, Katia.

Aos meus amigos e amigas que estiveram comigo durante estes anos, em especial Lenka, Ariane, Crissia e todos meus amigos latino-americanos pelo carinho, a amizade e por me fazer sentir como em casa.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo financiamento da bolsa de doutorado.

À Comissão Nacional de Energia Nuclear (CNEN), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e ao Instituto Nacional de Ciência e Tecnologia em Metrologia das radiações em Medicina (INCT) pelas contribuições financeiras para o desenvolvimento e divulgação das pesquisas realizadas.

DESENVOLVIMENTO DE ALGORITMOS PARA AVALIAÇÃO DA IMAGEM DO SIMULADOR PHANTOM MAMA PARA O CONTROLE DE QUALIDADE EM MAMOGRAFIA.

Carolina Marcela Vitoria Barragán

RESUMO

O exame mais indicado para o diagnóstico das patologias mamárias é a mamografia. Com o objetivo de garantir que o diagnóstico mamográfico seja feito corretamente e de forma eficiente, a Secretaria de Estado da Saúde de Minas Gerais criou o Programa Estadual de Controle de Qualidade em Mamografia. Um dos propósitos do programa é o monitoramento mensal da qualidade da imagem, que consiste em avaliar visualmente as imagens obtidas com simulador de mama nos serviços cadastrados. Com a análise visual não é possível expandir o Programa, devido à necessidade de pessoal treinado para realizar essa avaliação. O objetivo deste trabalho foi desenvolver e validar algoritmos para a avaliação automática das massas, fibras e microcalcificações presentes na imagem do *Phantom mama* reconhecido pelo Colégio Brasileiro de Radiologia e avaliar a concordância com a avaliação visual feita por humano. Foram desenvolvidos algoritmos utilizando imagens em filmes da base de dados do Programa de Monitoramento Mensal nos sistemas convencional, digital CR e DR e esses algoritmos foram ajustados para imagens adquiridas no mamógrafo que possui sistema CR instalado no LARAM/CDTN. As imagens adquiridas no CR foram obtidas usando diferentes parâmetros tais como Tensão, Carga, combinação Anodo/Filtro. Os algoritmos foram desenvolvidos em MATLAB® e as avaliações dos objetos de teste foram feitas seguindo os parâmetros dados pelo fabricante. Para a detecção das estruturas foram selecionadas as regiões de interesse nas quais foram aplicados procedimentos de pré-processamento, técnicas de segmentação e operadores morfológicos para o pós-processamento. Dados das duas avaliações (visual e automática) foram comparados e apresentaram concordâncias aceitáveis. Através da avaliação automática, foi possível diminuir a subjetividade causada pela avaliação humana. Concluiu-se será possível realizar a avaliação automática com os algoritmos desenvolvidos, avaliar a qualidade da imagem nos serviços de mamografia e expandir o Programa de Controle de Qualidade.

Palavras chaves: Mamografia, Processamento digital de imagens, Controle de Qualidade.

DEVELOPMENT OF ALGORITHMS FOR IMAGE EVALUATION OF PHANTOM MAMA FOR QUALITY CONTROL IN MAMMOGRAPHY.

Carolina Marcela Viloría Barragán

ABSTRACT

The most suitable test for the diagnosis of breast diseases is the mammography. In order to guarantee that the mammographic diagnosis is done properly and efficiently, the State Secretariat of Health of Minas Gerais created the State Program for Quality Control in Mammography. One purpose of the program is to monitor the image quality monthly, which consists of evaluating visually the images obtained using a breast phantom. With the visual analysis it is not possible to expand the program because of the need of trained personnel to carry out this evaluation. The goal of this study was to develop and validate algorithms for automatic evaluation of the masses, fibers and micro-calcifications present in *Phantom mam*, recognized by the Brazilian College of Radiology; and evaluate them in accordance with the visual assessment performed by humans. The algorithms were developed using films from database Monthly Monitoring Program acquired in conventional systems, digital CR and DR, that were later adjusted for images obtained in the mammography unit with CR system installed on LARAM/CDTN. These images were obtained using different parameters of Voltage, Load, combination Anode/Filter. The algorithms were developed in MATLAB® and evaluations of test objects were made following the parameters given by the manufacturer. For the detection of structures, selected regions of interest were selected in which pre-processing, segmentation techniques and morphological operators for post processing were applied. Data of the two evaluations (visual and automatic) were compared and it showed acceptable concordances. Through automatic evaluation, it was possible to reduce the subjectivity caused by human evaluation. It was concluded that it will be possible to perform automatic evaluation with the developed algorithms, evaluate the image quality on mammography services and expand the Quality Control Program.

Keywords: Mammography, Digital Image Processing, Quality Control.

ÍNDICE DE FIGURAS

Figura 1. Esquema de um Equipamento de Mamografia.	5
Figura 2. Configuração para um receptor de imagem de filme/écran mamografia.	6
Figura 3. Diagrama esquemático de uma unidade de leitura de dupla face CR. Algumas unidades de CR podem ler o sinal armazenado apenas a partir de um lado.	8
Figura 4. Detector de placa plana indireto com base em um cintilador CsI com silício amorfo (a-Si) diodos interruptores ou transistor de filme fino.	9
Figura 5. Detector de placa plana direta utilizando selênio amorfo (a-SE) como o absorvente de raios X.	9
Figura 6. Sistema de coordenadas para representação de imagens digitais.	10
Figura 7. Imagem com distintas resoluções. (a) 512x512 pixels. (b) 128x128 pixels. (c) 32x32 pixels.	11
Figura 8. Distintos tipos da mesma imagem (a) bem contrastada, (b) muito clara, (c) muito obscura e (d), (e), (f) seus respectivos histogramas.	13
Figura 9. Imagens caracterizadas por três diferentes níveis de ruído, a) ruído baixo, b) médio e c) alto.	14
Figura 10. Fluxo do processamento e análise de Imagens digitais.	15
Figura 11. Gray Nível Matrix e GLCM.	23
Figura 12. Elemento estrutural de dimensões de 3x3, pixel central S_{22}	25
Figura 13. Modo de operação do elemento estrutural sob a imagem I.	25
Figura 14. (a) Imagem binária inicial. (b) Imagem binária com Erosão. (c) Imagem binária dilatada.	26
Figura 15. Phantom mama reconhecido pelo Colégio Brasileiro de Radiologia.	27
Figura 16. Diagrama esquemático do Phantom mama.	28
Figura 17. Scanner ScanMaker 9800XL.	36
Figura 18. (a) Mamógrafo SIEMENS, Mammomat 3000 Nova. (b) Processadora de imagem modelo Kodak DirectView 850 System.	37
Figura 19. Posicionamento do Phantom mama para aquisição das imagens.	38
Figura 20. Imagem padrão.	38
Figura 21. Negatoscopio Planilu x Modelo DXHM 72X46cm.	39
Figura 22. Monitor específico para laudos de mamografia de 5 MP,	39
Figura 23. Histograma bimodal.	43
Figura 24. Histograma da ROI de m1.	43

Figura 25. Elemento estrutural em forma de disco de raio três.....	44
Figura 26. Grupo de microcalcificações (a) Depois da limiarização e (b) Depois de aplicar os operadores morfológicos.	45
Figura 27. Diagrama do PDI sob os grupos de Microcalcificações.	45
Figura 28. Seleção das ROIs de 250 x 250 pixels.	46
Figura 29. Sequência para aplicar a transformada de Hough.	48
Figura 30. Sequência do processamento das massas usando a Transformada de Hough.....	48
Figura 31. ROIs selecionadas para o cálculo da CNR.....	49
Figura 32. Grupos de microcalcificações depois do processamento digital.....	51
Figura 33. Comparação da avaliação visual e automática dos grupos de microcalcificações..	51
Figura 34. Massas depois do processamento digital.	53
Figura 35. Comparação da avaliação visual e semiautomática das massas nas imagens do phantom mama.	53
Figura 36. Fibras depois do processamento digital.	54
Figura 37. Comparação da avaliação visual e automática das fibras.	55
Figura 38. Correlação de Textura vs. Deslocamento Horizontal nas 4 ROIs.....	58
Figura 39. Comparação da avaliação visual e automática das grades nas imagens do Phantom mama.	58
Figura 40. Esquema das ROIs selecionadas na imagem do Phantom mama..	60
Figura 41. ROIs das grades metálicas da imagem digital adquirida no sistema CR.....	61
Figura 42. Correlação de Textura nas ROIs (grades) da imagem digital adquirida no sistema CR.....	62
Figura 43. Valores de CNR nos discos presentes na imagem do Phantom mama.	65

LISTA DE TABELAS

Tabela 1. Mascara dos operadores para detecção de contornos.	21
Tabela 2. Características dos atributos de textura.	23
Tabela 3. Avaliação do Coeficiente Kappa.	31
Tabela 4. Resumo de trabalhos publicados usando uma análise de computadorizado de imagens do phantom de mamografia.	35
Tabela 5. Características técnicas do mamógrafo MAMMOMAT 3000 Nova.	36
Tabela 6. Critérios de Avaliação das Grades.	47
Tabela 7. Tabela das frequências observadas em cada categoria.	50
Tabela 8. Frequências observadas dos grupos de microcalcificações.	52
Tabela 9. Estatística da concordância da avaliação visual e computacional dos grupos de microcalcificações.	52
Tabela 10. Frequências observadas das massas.	54
Tabela 11. Estatísticos da concordância da avaliação visual e computacional das massas.	54
Tabela 12. Frequências observadas das fibras.	55
Tabela 13. Estatísticos da concordância da avaliação visual e computacional das fibras.	56
Tabela 14. Resultados dos atributos de textura das ROIs de uma imagem padrão.	57
Tabela 15. Dimensões das ROIs para cada um dos objetos testes da imagem.	59
Tabela 16. Resultados da avaliação visual e automática de uma amostra de imagens digitais.	61
Tabela 17. Valor do atributo 'Energia' para as ROIs das grades.	62
Tabela 18. Frequências observadas das massas para imagens adquiridas no sistema CR.	63
Tabela 19. Frequências observadas dos grupos de microcalcificações para imagens adquiridas no sistema CR.	63
Tabela 20. Frequências observadas das fibras para imagens adquiridas no sistema CR.	63
Tabela 21. Frequências observadas das grades para imagens adquiridas no sistema CR.	63
Tabela 22. Valores Kappa que define a concordância entres os métodos de avaliação das estruturas.	64
Tabela 23. Valor de CNR dos discos.	65

LISTA DE SIGLAS E ABREVIACÕES

ACR	Colégio Americano de Radiologia (<i>American College of Radiology</i>)
ADN	Ácido desoxirribonucleico
a-Se	Selênio Amorfo
BIRADS	<i>Breast Imaging Reporting and Data System</i>
CAD	<i>Computer Aided Diagnosis</i>
CAE	Controle Automático de Exposição
CBR	Colégio Brasileiro de Radiologia
CDTN	Centro de Desenvolvimento da Tecnologia Nuclear
CIRS	<i>Computerized Imaging Reference System Inc.</i>
CNR	Razão Contraste Ruído (<i>Contrast Noise Ratio</i>)
CR	Radiografia Computadorizada (<i>Computed Radiography</i>)
del	<i>detector element</i>
DICOM	<i>Digital Imaging and Communications in Medicine</i>
DO	Densidade Ótica
dpi	Pontos por polegada (<i>Dots per inch</i>)
DR	Radiografia Digital (<i>Digital Radiography</i>)
DVSS	Diretoria de Vigilância em Serviços de Saúde
GLCM	Matriz de Co-ocorrência de Tons de Cinza (<i>Gray Level Co-occurrence Matrix</i>)
LARAM	Laboratório de Radioproteção aplicado a Mamografia
mAs	Miliampere-segundo
MS	Ministério de Saúde
PADI	Processamento e Análise Digital de Imagem
MATLAB	<i>Matrix Laboratory</i>
MTF	Função de Transferência de Modulação (<i>Modulation Transfer Function</i>)
PECQMamo	Programa Estadual de Controle de Qualidade em Mamografia
Pixel	<i>Picture Element</i>
PMMA	Polimetilmetacrilato
ROI	Região de Interesse (<i>Region of interest</i>)
SE	Elemento Estrutural (<i>Structural Element</i>)

SES-MG	Secretaria do Estado em Saúde – Minas Gerais
SIA	Sistema de Informação Ambulatória
SISMAMA	Sistema de Informação do Câncer de Mama
SUS	Sistema Único de Saúde
TIF	<i>Tagged Image File Format</i>
TFT	Transistor de Filme Fino
VISA-MG	Vigilância Sanitária – Minas Gerais

SUMARIO

1. INTRODUÇÃO	1
2. OBJETIVO	3
2.1 Objetivos específicos.....	3
3. FUNDAMENTOS TEÓRICOS.....	4
3.1 Detecção precoce do câncer de Mama	4
3.2 Sistemas de Aquisição de Imagens	6
3.2.1 Analógico	6
3.2.2 Sistemas Digitais	6
3.2.2.1 Sistema de Radiografia Computadorizada (CR)	7
3.2.2.2 Placa plana de CsI com o arranjo de fotodiodos.	8
3.2.2.3 Placa plana de Selênio amorfo com arranjo de eletrodos.....	9
3.3 Imagem digital	10
3.4 Fatores que influenciam a qualidade da imagem	11
3.4.1 Resolução da Imagem e Profundidade da Imagem	11
3.4.2 Brilho e Contraste.....	12
3.4.3 Ruído em Imagens	13
3.4.4 Entropia em Imagens	14
3.5 Processamentos e Análise Digital de Imagens (PADI)	15
3.5.1 Pré-processamento.....	16
3.5.1.1 Filtros Lineares	16
3.5.1.2 Filtros Não Lineares.	17
3.5.2 Técnicas de Segmentação.....	18
3.5.2.1 Limiarização	18
3.5.2.2 Detecção de Regiões.....	20
3.5.2.3 Detecção de contornos.....	20
3.5.2.4 Análise textura.....	22
3.5.3 Pós-Processamento	24
3.6 Simuladores de mama	26

3.6.1	Parâmetros de avaliação da qualidade da Imagem usando o Phantom Mama.	27
3.7	Programa de Monitoramento Mensal da Qualidade da Imagem	29
3.8	Análises Estatísticas.....	30
4.	ESTADO DA ARTE.....	32
5.	MATERIAIS E MÉTODOS	36
5.1	Amostragem e Equipamentos.....	36
5.2	Avaliação por observadores humanos	39
5.3	Avaliação computadorizada	40
5.3.1	Microcalcificações.....	41
5.3.2	Grades Metálicas	46
5.3.3	Massas e Fibras.....	48
5.3.4	Discos	49
5.4	Análise Estatística.....	49
6.	RESULTADOS E DISCUSSÃO	51
6.1	Imagens obtidas da base de dados da VISA.....	51
6.2	Imagens do LARAM	59
7.	CONCLUSÕES.....	66
	REFERÊNCIAS	67
	ANEXO.....	71

1. INTRODUÇÃO

No Brasil, o câncer de mama é o segundo tipo de câncer que mais acomete a população feminina seguido do câncer de pele não melanoma. Para os anos 2016/2017 foram estimados 57.960 novos casos de câncer de mama (INCA, 2015).

A mamografia é o método mais efetivo para a detecção precoce do câncer de mama. Este método consiste em uma técnica radiológica que permite a detecção de possíveis lesões com dimensões reduzidas por meio de microcalcificações de tamanhos menores a 0,5 mm, que podem ser fortes indícios do câncer de mama em formação, em uma fase muito inicial (KOOMEN, 2005; PERRY, 2008). A mamografia utiliza baixas doses de radiação, mas tem um risco associado essas doses. Os danos mais importantes associados a detecção precoce do câncer de mama através do rastreamento mamográfico são falsos resultados positivos, sobre diagnóstico e, possivelmente câncer radio-induzido. (IARC, 2015).

A mamografia pode ser para rastreamento e/ou diagnóstico. A mamografia de rastreamento é a aplicação sistemática de um exame, em populações assintomáticas, para identificar mulheres com anormalidades sugestivas de câncer. O rastreamento pode ser populacional, quando há iniciativas populacional ou oportuníssimo, quando as pessoas procuram espontaneamente os serviços de saúde. A mamografia de diagnóstico consiste em identificar lesões em fases iniciais, em mulheres com algum sinal de câncer de mama (nódulo, retração do mamilo etc.) (INCA, 2010).

A detecção do câncer de mama depende muito da qualidade da imagem mamográfica. Por isso é importante implementar programas de garantia de qualidade, e assim oferecer à população exames de mamografia dentro de padrões de qualidade para a detecção precoce e, conseqüentemente, reduzir a mortalidade por este tipo de câncer. No Estado de Minas Gerais, a Secretaria de Estado de Saúde (SES-MG) através da Superintendência de Vigilância Sanitária criou, em 2004, o Programa Estadual de Controle de Qualidade em Mamografia – PECQMamo (BRASIL, 2004).

Um dos objetivos desse programa é o monitoramento mensal da qualidade da imagem. Tal monitoramento consiste na avaliação das imagens produzidas nos serviços de mamografia com simulador de mama. A qualidade de uma imagem de referência (imagem de um simulador de mama - *phantom mama*) garante visualizar estruturas como massas,

microcalcificações e fibras, assim como características da imagem como o contraste e a resolução espacial (PEIXOTO, 2011). As imagens dos simuladores são avaliadas visualmente por um grupo de pessoas capacitadas para contabilizar os objetos testes presentes na imagem. As avaliações são feitas de acordo com os critérios definidos na Portaria SVS/MS nº 453/98 “Radiodiagnóstico Médico, Segurança e Desempenho de Equipamentos” (BRASIL, 1998).

Nas últimas décadas, centros de pesquisa tem buscado desenvolver técnicas computacionais de processamento de imagens para auxiliar a detecção precoce de estruturas indicativas do câncer de mama. Essas técnicas de processamento, conhecidas como Diagnóstico Auxiliado por Computador (*Computer Aided Diagnosis – CAD*) vem sendo utilizadas comercialmente desde 1998 em centros de diagnóstico por imagem, principalmente nos Estados Unidos e na Europa. A utilização de esquemas CAD tem ajudado os radiologistas com uma análise computadorizada das imagens de raios X, fornecendo uma segunda opinião da detecção de lesões e na elaboração do diagnóstico. Diversos estudos sobre essas ferramentas têm mostrado que sua utilização pode melhorar o desempenho de radiologistas no diagnóstico (GIGER, 2008; BRANCATO, 2008; TAYLOR, 2008; DI MAGGIO, 2004; FUJITA, 2008).

Inúmeros artigos têm sido publicados apresentando a aplicação das técnicas de processamento de imagens e ilustram o potencial da análise automática aplicada às imagens dos objetos simulador e a importância de padronizar a avaliação da qualidade da imagem (BROOKS, 1997; GENNARO, 2010; MAYO, 2010; CHAKRABORTY, 2010).

O Estado de Minas Gerais tem, atualmente, cerca de 500 mamógrafos em funcionamento. Aproximadamente 90 mamógrafos estão cadastrados no Programa de Monitoramento Mensal, quem por sua vez tem limitação de profissionais para realizar a avaliação visual das imagens e espaço físico para armazenamento. Adicionalmente, nos últimos anos há uma tendência de mudar o sistema de aquisição das imagens a sistemas digitais, com mira a realização de laudos de mamografia em monitores de alta resolução (BRASIL, 2012). As informações do programa são divulgadas para a população através do sistema de informação ATALANTA, site desenvolvido pelo Centro de Desenvolvimento da Tecnologia Nuclear (CDTN) em parceria com a Vigilância Sanitária do Estado de Minas Gerais (VISA/MG) para o armazenamento de dados obtidos dos serviços de mamografia públicos e privados do Estado de Minas Gerais.

2. OBJETIVO

Desenvolver algoritmos para auxiliar a avaliação automática das massas, microcalcificações, fibras e grades presentes na imagem do simulador *phantom mama* mimetizando a acuidade visual humana.

2.1 Objetivos específicos

- Pesquisar, aplicar e analisar métodos de detecção das estruturas presentes em imagens do phantom mama.
- Verificar a viabilidade do uso das imagens do banco de dados da Vigilância Sanitária (VISA) e das imagens adquiridas em um mamógrafo específico (LARAM).
- Comparar as metodologias de desenvolvimento da avaliação automática para as imagens adquiridas na VISA e no LARAM.
- Verificar a concordância dos algoritmos com avaliadores visuais.

3. FUNDAMENTOS TEÓRICOS

3.1 Detecção precoce do câncer de Mama

Câncer é o nome genérico para um grupo de mais de 100 doenças. Embora existam muitos tipos de câncer, todos começam devido ao crescimento anormal e fora de controle das células. O câncer da mama começa no tecido mamário que é composto de glândulas para a produção de leite, chamados lóbulos, e dos condutos que ligam os lóbulos ao mamilo. O restante da mama está composto de tecido adiposo, conjuntivo e tecidos linfáticos (ACS, 2013).

Muitos fatores conhecidos por incrementar o risco de câncer de mama não são modificáveis, como idade, história familiar, menarca precoce e menopausa tardia. Fatores que são modificáveis incluem obesidade pós-menopausa, uso de estrogênios combinados e progesterona como hormônios da menopausa, consumo de álcool, e amamentação. Muitos fatores de risco de câncer de mama afetam a exposição do tecido mamário aos hormônios (menarca precoce, menopausa tardia, obesidade e uso de hormônios (ACS, 2015).

A mamografia é um procedimento radiográfico dedicado ao diagnóstico de patologias da mama. É um método altamente eficaz na detecção do câncer de mama inicial, pois permite detectar nódulos ou tumores não palpáveis (INCA, 2010).

No Brasil, o Ministério da Saúde (MS) publicou um documento sobre o Controle do Câncer de Mama, recomendando as seguintes ações para rastreamento em mulheres assintomáticas. Exame clínico das mamas a partir dos 40 anos, mamografia para mulheres entre 50 e 69 anos, com intervalo máximo de dois anos entre os exames e exame clínico das mamas e mamografia anual, a partir dos 35 anos, para mulheres do grupo de risco (BRASIL, 2007).

Os equipamentos dedicados a realização de exames mamográfico são os mamógrafos (Fig. 1). Esses equipamentos apresentam grandes diferenças estruturais comparados a outros equipamentos que usam raios X, devido à anatomia da mama, considerando sua forma cônica e a espessura que diminui consideravelmente desde a parede torácica até o mamilo. A mama é composta basicamente pela pele, tecido glandular e tecido adiposo. Esses tecidos e estruturas têm composição química muito semelhante entre eles, ou seja, os coeficientes de atenuação linear são muito próximos, portanto é necessária a utilização de fótons de baixa energia para diferenciar as estruturas na imagem (JAKUBIAK, 2013).




Figura 1. Esquema de um Equipamento de Mamografia.
Fonte: IAEA, 2014.

Os raios X se originam principalmente da desaceleração dos elétrons quando acontece a interação com o núcleo dos átomos do ânodo, no ponto focal. Nos equipamentos de mamografia usualmente são encontrados dois pontos focais de tamanhos de 0.3 e 0.1 mm. A carga elétrica no tubo, ou seja, o produto da corrente elétrica pelo tempo (mAs), determinam a quantidade de fótons de raios X. O espectro do feixe de radiação produzido pelo equipamento é determinado pela diferença de potencial elétrica (Quilovolt pico, kVp) aplicada ao tubo de raios X e pela combinação ânodo/filtro do tubo de raios X, onde a maioria dos equipamentos convencionais possuem a combinação Molibdênio/Molibdênio (Mo/Mo) e muitos estão equipados com combinações Molibdênio/Ródio (Mo/Rh), Tungstênio/Ródio (W/Rh) e Ródio/Ródio (Rh/Rh). Novos filtros têm sido introduzidos com a utilização crescente de equipamentos digitais, como filtros de Prata (Ag) e alumínio (Al). A janela do tubo, por onde o feixe é emitido, é composta geralmente de Berílio (Be) para que não exista atenuação significativa da radiação produzida (PAIXÃO, 2015).

O mamógrafo utiliza de um dispositivo de compressão (bandeja de compressão) para melhorar a resolução espacial e o contraste na imagem, o que evita a sobreposição das estruturas anatômicas, além de reduzir a dose e o tempo de exposição. O mamógrafo possui uma grade antiespalhamento que aumenta o contraste da imagem e o controle automático de exposição (CAE) é aplicado para assegurar uma ótima exposição (BUSHONG, 1998).

3.2 Sistemas de Aquisição de Imagens

3.2.1 Analógico

No sistema de aquisição de imagens mamográficas analógicas se faz uso do sistema filme-écran. As imagens são gravadas em filmes formados por uma base de acetato ou poliéster, que serve para dar sustentação ao filme, uma camada de Haletos (Brometo e iodeto) de prata que interage com os raios X e uma camada protetora (Fig. 2). O écran (tela intensificadora de imagem) possui uma camada fluorescente, que consiste de oxissulfitos de terras raras. Este material fluorescente tem a propriedade de emitir luz quando irradiado por um feixe de raios X. É a luz que irá impressionar o filme radiográfico. Apenas 5% da imagem será formada pela ação direta de raios X, 95% será formada pela ação da luz proveniente das telas intensificadoras, resultando em um alto rendimento (OLIVEIRA, 2007). Após o filme ser exposto a radiação, passa por um processamento de revelado e fixação por agentes químicos.




Figura 2. Configuração para um receptor de imagem de filme/écran mamografia.
Fonte: IAEA, 2014.

3.2.2 Sistemas Digitais

Existem dois tipos de sistema detector de mamografia digital. Um utiliza uma placa de fósforo foto-estimulável mantida num cassete durante a exposição. Esse sistema é frequentemente referenciado como Radiografia Computadorizada (*Computed Radiography* - CR). Os sistemas contendo outros tipos de detector, normalmente integrados no equipamento de mamografia são referenciados como sistemas de Radiografia Digital (*Digital Radiography* - DR) (IAEA, 2011).

De acordo com o método de captura, eles são classificados como de captura direta ou indireta da imagem.

No sistema de captura direta, os fótons de raios X que foram transmitidos através da mama interagem diretamente como uma placa de material fotocondutor de Selênio amorfo (a-Se) que converte os raios X absorvidos em sinal elétrico em um dos elementos da matriz de detectores sendo convertido em um sinal digital, sistema classificado como sistema DR de captura direta (JAKUBIAK, 2013).

O método de captura indireta usa um processo de duas etapas para a aquisição da imagem. Neste método estão inseridos os seguintes sistemas: Cintilador de Placa plana única, que utiliza como detector de raios X o CsI(Tl) (*single flat-panel scintillator*) e matriz de fotodiodos, classificado como sistema DR de conversão indireta, e os sistemas que utilizam placas de fósforo fotoestimulável (Sistema de mamográfica computadorizada ou CR), onde o detector é o Flúor Brometo de Bário – BaFBr (JAKUBIAK, 2013).

3.2.2.1 Sistema de Radiografia Computadorizada (CR)

O sistema de Radiografia Computadorizada (CR) utiliza um material de fósforo fotoestimulável a raios X, tipicamente de um Flúor Brometo de Bário (BaFBr). A resposta à absorção dos raios X são fotoelétrons energéticos liberados no cristal. Estes perdem parte de sua energia pela interação e excitam os elétrons da fronteira ligados na rede cristalina. Alguns destes elétrons tornam-se confinados no material cristalino do fósforo, onde permanecem estáveis durante algum tempo. O número de elétrons capturados é proporcional à quantidade de radiação incidente no fósforo. Após a exposição, a placa de fósforo é colocada num dispositivo de leitura em que é digitalizada com um fino feixe de laser (Fig. 3). A luz do laser “descarrega” as armadilhas, fazendo com que os elétrons retornem ao seu estado fundamental. Ao fazê-lo, os elétrons fazem a transição entre estados de energia gerados por elementos específicos dopantes incorporados na rede cristalina. Isto faz com que a energia liberada na forma de fótons de luz tenha um comprimento de onda determinado pela escolha do agente dopante. Tipicamente, este comprimento de onda é diferente do da luz laser estimulante. Esta luz emitida é recolhida a partir das superfícies superior e/ou inferior da placa e medida com um detector fotoelétrico. O sinal resultante é digitalizado para formar a imagem. Em sistemas CR, uma transformação não linear (normalmente logarítmica) é aplicada ao sinal durante a digitalização (IAEA, 2011).

Nos sistemas CR usados para mamografia às placas de fósforo sensíveis aos raios X são inseridas em cassetes, que para a obtenção da imagem devem ser inseridos no equipamento de mamografia. Isso apresenta algumas vantagens, por um lado permite que a mamografia digital seja realizada numa unidade de mamografia convencional e também que várias unidades

possam compartilhar um único leitor (cassetes), o que reduz significativamente os custos. Mas a entrada manual de dados é suscetível a erros na rotulagem das imagens. Além disso, artefatos de poeira também são mais prováveis de ocorrer em um sistema de cassete, sendo que a maioria dos sistemas CR não fornece um meio achatamento do campo (*Flat Fielding*) que permite corrigir a falta de uniformidade da sensibilidade da placa ou variações no campo dos raios X (IAEA, 2011).




Figura 3. Diagrama esquemático de uma unidade de leitura de dupla face CR. Algumas unidades de CR podem ler o sinal armazenado apenas a partir de um lado.
Fonte: IAEA, 2011.

3.2.2.2 Placa plana de CsI com o arranjo de fotodiodos.

No sistema de arranjo de fotodiodos uma camada de fósforo CsI(Tl) é depositado diretamente sobre uma matriz de fotodiodos, formados sobre uma placa plana de substrato de silício amorfo (a-Si, ou α -Si) (Fig. 4). Cada elemento de diodo sensível à luz é ligado por um interruptor de transistor de filme fino (*Thin Film Transistor* - TFT) para uma série de linhas de controle e linhas de dados, de tal modo que a carga produzida no diodo em resposta à emissão de luz da substância fosforescente seja lida, e possa ser digitalizada. Em tais sistemas, o sinal inicial formando a imagem DICOM “para processamento” é linear com a quantidade de energia absorvida pela substância fosforescente (IAEA, 2011).

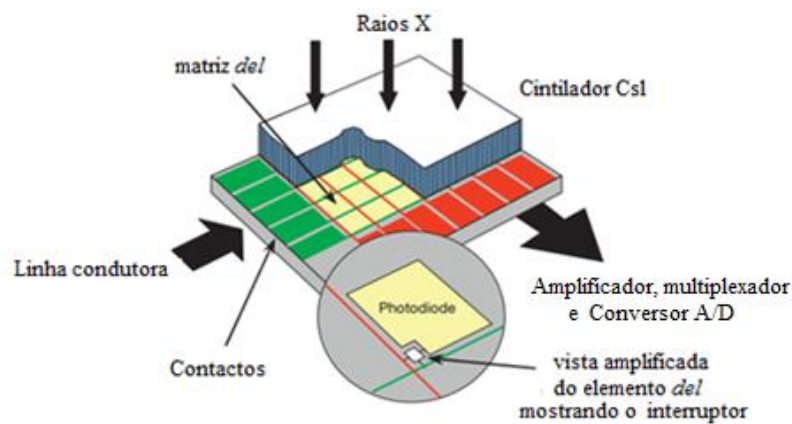


Figura 4. Detector de placa plana indireto com base em um cintilador CsI com silício amorfo (a-Si) diodos interruptores ou transistor de filme fino.
Fonte: IAEA, 2011.

3.2.2.3 Placa plana de Selênio amorfo com arranjo de eletrodos.

Este sistema não utiliza a camada de fósforo. Em vez disso, os raios X são absorvidos em uma camada de Selênio amorfo (a-SE, ou α -SE), que é depositado sobre uma matriz de eletrodos formados sobre uma grande área de um substrato de Si (Fig. 5). Um campo elétrico é imposto através da placa para recolher os pares elétron-buraco liberados mediante a absorção de raios X. As cargas se movem para o eletrodo onde são coletadas. Durante o procedimento de leitura, os transistores (TFT) em cada elemento detector (*detector element - del*) são sequencialmente ativados, uma linha de cada vez através de linhas de controle, e a carga é recolhida ao longo de linhas de dados conectando cada *del* para leitura eletrônica semelhante à aqueles no sistema de Placa plana de CsI (IAEA, 2011).




Figura 5. Detector de placa plana direta utilizando selênio amorfo (a-SE) como o absorvente de raios X.
Fonte: IAEA, 2011.

3.3 Imagem digital

A imagem digital é composta de um número finito de elementos, cada um possuindo localização e valor particulares. Estes elementos são chamados de elementos de imagem ou *pixels* (*picture element*). *Pixel* é o termo mais utilizado para denotar os elementos de imagem no campo do processamento de imagens digitais (GONZALEZ, 2000).

Uma imagem pode ser definida como uma função bidimensional, $f(x,y)$, onde x e y são coordenadas espaciais (plano), e o valor da amplitude de f no ponto (x,y) é uma grandeza escalar positiva cujo significado físico é determinado pela fonte da imagem. No caso de imagens médicas, o valor da função determina um tom de cinza e o significado físico deste enegrecimento é o nível de atenuação dos raios X (fonte da imagem) pelo tecido do paciente ou do simulador mamográfico. A esse valor de intensidade de uma imagem monocromática f nas coordenadas (x, y) denomina-se *tom de cinza* (L), o valor L ficara restrito entre o intervalo $[L_{\min}, L_{\max}]$ denominado *escala de cinza* (GONZALEZ, 2000).

Na determinação desses valores são necessários dois processos: amostragem e quantização. Uma imagem para ser adequada para processamento computacional, precisa ser digitalizada tanto espacialmente quanto em amplitude. A digitalização das coordenadas espaciais (x, y) é denominada *amostragem* da imagem e a digitalização da amplitude é chamada *quantização em níveis de cinza* (GONZALEZ, 2000). O processo de amostragem consiste em converter o sinal analógico em uma matriz de números reais $M \times N$ pontos, M linhas e N colunas, onde cada elemento da matriz é um pixel (Fig. 6). A quantização faz com que cada um destes pixels assuma um valor inteiro, na faixa de 0 a 2^{k-1} . Quanto maior o valor de k , maior o número de níveis de cinza presentes na imagem digitalizada (FILHO, 1999).




Figura 6. Sistema de coordenadas para representação de imagens digitais.
Fonte: GONZALEZ, 2000.

O processo de digitalização exige decisões sobre os valores de M , N e para o número, L , de níveis de cinza discretos permitidos para cada pixel. Não existem requisitos para M e N , exceto que sejam números inteiros positivos. No entanto, devido a considerações de *hardware* para processamento, armazenamento e amostragem, o número de níveis de cinza é tipicamente uma potência inteira de 2: $L = 2^k$. Assumimos que os níveis discretos são igualmente espaçados e que eles são inteiros no intervalo $[0, L-1]$. Por vezes, o intervalo de valores estendidos pela escala de tons de cinza é chamado intervalo dinâmico da imagem. Quando uma imagem pode ter 2^k níveis de cinza, é comum se referir à imagem como uma “imagem de k bits.” Por exemplo, uma imagem com 256 valores possíveis de níveis de cinza é chamada de uma imagem de 8-bits (GONZALEZ, 2000).

3.4 Fatores que influenciam a qualidade da imagem

3.4.1 Resolução da Imagem e Profundidade da Imagem

A resolução espacial é a capacidade de imagem digital para mostrar os detalhes exatos da imagem original, conceito este associado à densidade de pixels da imagem. Quanto menor o intervalo de amostragem, maior será a resolução da imagem. A resolução pode ser representada pela quantidade de pontos por polegada (*dots per inch* - dpi), e descreve a capacidade máxima de discriminação de dois pontos na imagem digital. Ou simplesmente pode ser representada pelo tamanho da matriz. A diferença entre uma imagem com diferentes resoluções pode se ver na Figura 7.




Figura 7. Imagem com distintas resoluções. (a) 512x512 pixels. (b) 128x128 pixels. (c) 32x32 pixels.
Fonte: GONZALEZ, 2000.

A resolução espacial ou detalhes em uma mamografia é uns dos parâmetros mais importantes para a visualização de calcificações e de estruturas fibrosas finas, e para a clara demarcação dos contornos dos nódulos na detecção do câncer de mama. A resolução espacial de um sistema pode ser determinada de duas formas: umas delas consiste em determinar o número de pares de linha por milímetro (lp/mm) de um objeto com padrões de barras paralelas separadas entre si, e a outra forma é determinar sua função de transferência de modulação (MTF), que descreve as propriedades de resolução espacial como função da frequência espacial em uma direção pré-definida (JAKUBIAK, 2013).

3.4.2 *Brilho e Contraste*

Uma imagem formada predominantemente por pixels com valores de tons de cinza altos é percebida como uma imagem clara, ou seja, de alto brilho. Já uma imagem que contém predominantemente pixels com tons de cinza próximos ao zero (preto), é considerada uma imagem escura, ou seja, de baixo brilho. Da mesma forma, quando uma imagem apresenta pixels com uma grande variação de tons de cinza, a imagem é percebida como de alto contraste. Enquanto, que uma imagem que apresenta pequena variação de tons de cinza no espaço, é percebida como uma imagem de baixo contraste.

Na representação matemática de uma imagem digital, definida com a função $f(x,y)$ de dimensões $M \times N$, o número total de pixels da imagem representado por n pode ser obtido conforme Equação 1,

$$n = M \cdot N \quad \text{(Equação 1)}$$

onde M e N são o número de pixels no eixo x e y , respectivamente.

O brilho da imagem é definido como a média dos tons de cinza de todos os pixels da imagem e o contraste de uma imagem digital pode ser definido como o desvio padrão dos tons de cinza de todos os pixels da imagem (GONZALEZ, 2000).

Com um histograma é possível obter uma representação gráfica da distribuição dos tons de cinza dos pixels numa imagem digital (Fig. 8). Nas abcissas se representam todos os possíveis tons de cinza da imagem, e nas ordenadas o número de pixels que aparece na imagem cada tom de cinza.




Figura 8. Distintos tipos da mesma imagem (a) bem contrastada, (b) muito clara, (c) muito obscura e (d), (e), (f) seus respectivos histogramas.
Fonte: MATLAB, 2016.

3.4.3 Ruído em Imagens

O Ruído consiste na degradação que sofrem as imagens durante seu processo de aquisição, transmissão ou processamento.

Nas imagens radiográficas o ruído está composto pelo ruído quântico, eletrônico e estrutural, cada um devido à fonte. O principal componente é o ruído quântico que está associado a flutuações estatísticas no fluxo de fótons incidentes no detector e as variações aleatórias na absorção. A maneira mais simples de caracterizar o ruído é a medida do desvio padrão (σ) do número de fótons absorvidos (N) em uma região do detector. Este número segue a distribuição de Poisson, $\sigma=N^{1/2}$. O ruído estrutural nos detectores digitais tem sua origem na falta de homogeneidade na sensibilidade dos elementos detectores, o que vem da variação espacial fixa da estrutura de detecção da imagem. Esse ruído provoca o aparecimento de um fundo estruturado na imagem que geralmente é removido através de técnicas de planificação do campo (*flat field*), que são técnicas que incluem a criação de mascaras corretivas a partir de uma imagem direta e uniforme do feixe de raios X. A estes dois tipos de ruído adiciona-se o eletrônico que surge da leitura eletrônica originada nos circuitos de leitura e na amplificação do sinal (CHEVALIER, 2010).

A Figura 9 apresenta três imagens caracterizadas por três diferentes níveis de ruído baixo, médio e alto.

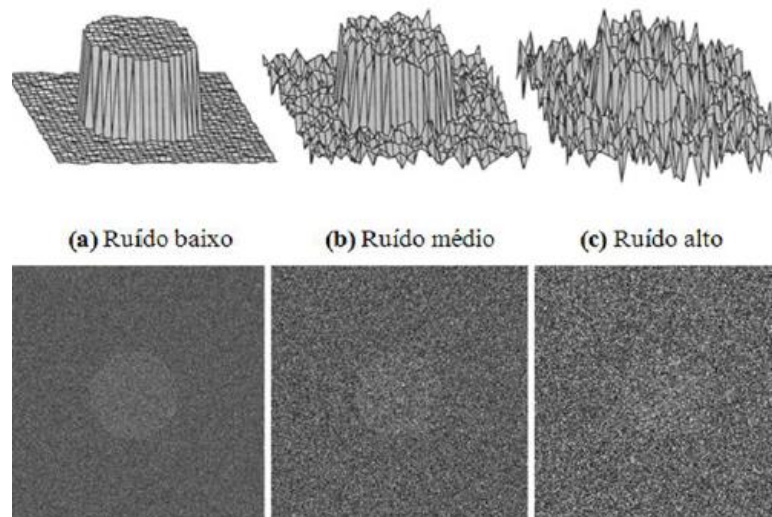


Figura 9. Imagens caracterizadas por três diferentes níveis de ruído, a) ruído baixo, b) médio e c) alto.
Fonte: IAEA, 2015.

3.4.4 Entropia em Imagens

Uma imagem pode ser considerada como o resultado de um processo aleatório, no qual a probabilidade p_i corresponde a probabilidade de um pixel em uma imagem digital assumir o valor de intensidade i , $i= 0, 1, \dots L_{\max}$. A distribuição dos níveis de intensidade da imagem pode ser transformada em uma função densidade de probabilidade (Equação 2), dividindo-se o número de pixels de intensidade i , denotado n_i , pelo número total n de pixels na imagem,

$$p_i = \frac{n_i}{n} \quad (\text{Equação 2})$$

O cálculo da entropia H de uma imagem pode ser realizado através da Equação 3.

$$H = -\sum_{i=0}^{L_{\max}} p_i \log_2 p_i \quad (\text{Equação 3})$$

A entropia da imagem pode ser definida como um número quantificador da randomicidade da imagem, ou seja, quanto maior for este número, mais irregular, atípica ou despadronizada será a imagem analisada. O menor valor para a entropia é zero, ocorrendo quando todos os pixels possuem uma mesma intensidade de cinza. Por outro lado, a máxima entropia ocorre quando uma imagem contém a mesma quantidade de pixels para todas as intensidades. (GUIMARÃES, 2013).

3.5 Processamentos e Análise Digital de Imagens (PADI)

O processamento digital de imagens consiste em ferramentas que permitem transformar uma imagem digital utilizando operações que alteram os valores dos pixels e dessa forma facilitam e melhoram a visualização da imagem pelo observador. Os sistemas de processamento e análise digital de imagens são basicamente programas de computador que executam em imagens digitais rotinas de procedimentos baseados em operações matemáticas, onde essas rotinas implementadas seguem uma sequência padrão (Fig. 10) que é dividida em três blocos básicos: aquisição de imagem digital, processamento digital de imagem (PDI) e análise digital de imagem (ADI) (GONZALEZ, 2000).

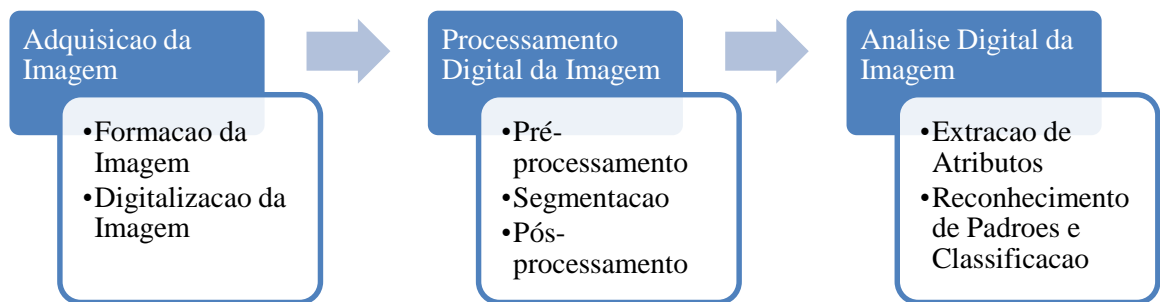


Figura 10. Fluxo do processamento e análise de Imagens digitais.
Fonte: Adaptado de Gonzalez 2000.

A aquisição da imagem digital pode ser feita através da utilização de um sensor que capture o sinal da imagem e faça sua digitalização (amostragem e quantização), ou por meio do processamento de uma ou mais imagens já digitalizadas gerando uma nova ou criando-se uma imagem já digital. No bloco PDI, onde a imagem é processada através de suas três etapas, pré-processamento, segmentação e pós-processamento, constituindo-se como a fase qualitativa do processo. A etapa de pré-processamento é a etapa que visa melhorar a imagem, corrigindo defeitos gerados durante sua aquisição e/ou realçando detalhes de interesse específico. A imagem de saída dessa etapa é a imagem segmentada, e a imagem de saída do pré-processamento é uma imagem binária formada por objetos que são de interesse específico. Essa imagem é representada por regiões formadas por pixels contíguos de mesmo valor. Nas etapas de pós-processamento e extração de atributos, trabalha-se diretamente sobre os objetos. Na etapa de pós-processamento se corrige defeitos ocorridos na etapa de segmentação,

extraindo-se objetos que não são de interesse, e até mesmo juntando ou separando-os (GOMES, 2001).

3.5.1 *Pré-processamento*

A etapa de pré-processamento visa melhorar a qualidade da imagem por meio de aplicação de técnicas para atenuação de ruído, correção de contraste ou brilho, e suavização de determinadas propriedades da imagem. Os procedimentos da etapa de pré-processamento podem ser realizados em dois domínios: no domínio espacial ou no domínio das frequências. As técnicas no domínio espacial baseiam-se em filtros que manipulam o plano da imagem, enquanto que as técnicas de processamento no domínio da frequência se baseiam em filtros que agem sobre o espectro da imagem (DINIZ, 2010).

A imagem é transformada do domínio espacial para o domínio da frequência, usando a transformada de Fourier. Depois operações de filtragem são realizadas nessa imagem, e finalmente realiza-se o processo inverso, onde a imagem no domínio da frequência é transformada para o domínio espacial (GONZALEZ, 2000). Os métodos de filtragem que trabalham no domínio espacial operam diretamente sobre os pixels, normalmente utilizando operações de convolução com máscaras. O uso de máscaras nas imagens no domínio espacial é usualmente chamado de filtragem espacial e as máscaras são chamadas de filtros espaciais, conforme Equação 4.

$$g(x_i, y_i) = T[f(x_i, y_i)] \quad (\text{Equação 4})$$

onde $f(x,y)$ é a imagem de entrada a ser filtrada, $g(x,y)$ é a imagem na saída processada e, T é um operador sobre f , definido em alguma vizinhança do pixel de posição (x,y) .

Os tipos de Filtros podem se classificar em Lineares e não lineares. Os filtros Lineares se caracterizam em suavizar, realçar detalhes da imagem e minimizar efeitos de ruído, sem alterar o nível médio de cinza da imagem. Em quanto os filtros não lineares aplicam transformações sem o compromisso de manterem o nível médio de cinza da imagem original (THOMÉ, 2004).

3.5.1.1 Filtros Lineares

No domínio do espaço, os métodos de filtragem espacial operam diretamente sobre a matriz de pixels (imagem digitalizada); utilizando operações de convolução entre a imagem

original e uma máscara especialmente construída. Essas máscaras são chamadas de filtros espaciais.

- Filtros Passa-baixas: também conhecidos como filtros de Média, tem a característica de eliminar informações de alta frequência, ou seja, extrair informações muito discrepantes (em geral ruídos) da imagem digital. Suavizam a informação da imagem: o resultado da aplicação desse filtro é a geração de uma imagem de saída mais homogênea, ou mais suavizada, em comparação com a imagem original deixando passar apenas as componentes de mais baixa frequência (atenuam o contraste).

- Filtros Passa-altas se caracterizam por realçar a imagem ou alvos presentes na imagem digital, aumentar a nitidez das transições entre diferentes regiões de uma imagem digital. Podem funcionar como detectores de pontos isolados, de linhas e de bordas presentes na imagem.

- Filtros Passa-banda utilizados para remover frequências baixas e altas. Esse filtro é mais utilizado em processamentos específicos, principalmente para remover ruídos periódicos.

3.5.1.2 Filtros Não Lineares.

Os filtro não lineares são chamados de filtros estatísticos que podem atuar também no domínio da frequência ou domínios espaciais.

No domínio espacial esses filtros são utilizados para suavizar a imagem. Como são o *Filtro de Mediana*, que suaviza a imagem sem diminuir sua resolução (borrar), os pontos da vizinhança de (x, y) , dentro de uma janela da imagem, são ordenados e tomados como novo valor para (x, y) o valor mediano desta ordenação. O *Filtro de Ordem*, onde os pontos da vizinhança de (x, y) , dentro de uma janela da imagem, são ordenados e tomado como novo valor para (x, y) o valor máximo ou o valor de uma ordem qualquer desta ordenação. E o *Filtro de Moda*, onde os pontos da vizinhança de (x, y) , dentro de uma janela da imagem, são ordenados e tomados como novo valor para (x, y) o valor mais frequente da vizinhança, se utiliza para eliminar ruídos pontuais, sem alterar muito as informações da imagem (THOMÉ, 2004).

No domínio da frequência se aplica a filtragem Homomórfica, trata-se de uma abordagem que busca operar sobre as componentes de iluminação e reflectância separadamente. A componente de iluminação de uma imagem é geralmente caracterizada por variações espaciais lentas; em quanto à reflectância tende a variar abruptamente, particularmente na junção de objetos diferentes (THOMÉ, 2004).

3.5.2 Técnicas de Segmentação

A etapa de segmentação realiza a extração e identificação de áreas de interesse contidas na imagem (GONZALEZ, 2000). Essa técnica pode ser baseada em diferentes princípios descritos a continuação:

- A limiarização, na qual os pixels da imagem se classificam atendendo unicamente o seu tom de cinza.
- Detecção de regiões, na qual os pixels da imagem com características similares se agrupam em regiões.
- Detecção de contornos, na qual se identificam os pixels que correspondem as fronteiras que separam dois objetos diferentes.
- Análise de textura, na qual se caracterizam zonas segundo a distribuição espacial dos tons de cinza dos pixels.

3.5.2.1 Limiarização

A limiarização é uma das técnicas mais simples de segmentação e consiste na classificação dos pixels de uma imagem de acordo com a especificação de um ou mais limiares. O processo consiste em definir um tom de cinza como limiar, de forma que os pixels se classificam em determinado valor segundo esses sejam inferior ou superior ao limiar. A partir de um limiar T , a imagem limiarizada $g(x,y)$ pode ser definida conforme Equação 5.

$$g(x,y) = \begin{cases} 0, & \text{se } f(x,y) \leq T \\ 1, & \text{se } f(x,y) > T \end{cases} \quad (\text{Equação 5})$$

onde normalmente os pixels rotulados como a unidade correspondem aos objetos, enquanto que aqueles rotulados com zero correspondem ao fundo. Nesse caso a limiarização é denominada *binarização*, pois a imagem resultante possui apenas dois valores de intensidade, 0 (preto) ou 1 (branco) (GONZALEZ, 2000).

Um caso mais geral dessa abordagem, quando a imagem tem uma série de objetos com diferentes tons de cinza, existe a possibilidade de aplicar vários limiares na imagem que delimitem os objetos que nela aparecem. Assim a limiarização da imagem pode ser definida conforme Equação 6.

$$g(x, y) = \begin{cases} l_1, & \text{se } f(x, y) \leq T_1 \\ l_2, & \text{se } T_1 < f(x, y) \leq T_2 \\ \vdots & \\ l_n, & \text{se } f(x, y) > T_n \end{cases} \quad (\text{Equação 6})$$

Onde l_1, l_2, \dots, l_n são os valores do tom de cinza assinado a cada intervalo definido pelos valores limiares T_1, T_2, \dots, T_n . Os valores de limiarização podem ser uma constante ou uma função, cujo valor calculado é definido a partir de características locais ou globais. A *limiarização global* se utiliza em um único valor de limiar para segmentar toda a imagem. Em geral não é adequada, pois as imagens podem conter variações nos níveis de cinza dos objetos e do fundo por causa de iluminação não uniforme, ruído entre outros. E a *limiarização local* consiste em analisar as intensidades dos pixels em uma região da imagem para determinar limiares locais.

Algumas medidas estatísticas simples para calcular um limiar local são a média dos valores de intensidade em uma vizinhança local da imagem, conforme Equação 7.

$$T = m_v(p) \quad (\text{Equação 7})$$

Onde m_v é a média da vizinhança no ponto p .

A mediana dos valores é calculada conforme Equação 8.

$$T = med_v(p) \quad (\text{Equação 8})$$

Onde med_v é a mediana da vizinhança no ponto p .

A média dos valores mínimo e máximo calculada conforme Equação 9.

$$T = \frac{\min_v(p) + \max_v(p)}{2} \quad (\text{Equação 9})$$

Em que v é uma vizinhança local ao ponto p na imagem.

Outros valores limiares podem ser definidos com o método de Niblack, onde o valor do limiar em um pixel (x, y) é baseado na média local e no desvio padrão calculado sobre uma vizinhança de tamanho $n \times n$ pixels, expressada conforme Equação 10.

$$T(x, y) = \mu(x, y) + k\sigma(x, y) \quad (\text{Equação 10})$$

onde $\mu(x, y)$ e $\sigma(x, y)$ são a média e o desvio padrão dos valores sobre a vizinhança, respectivamente. O valor k é ajustado conforme o tipo de aplicação ou característica da imagem sendo processada (SEIXAS, 2008).

3.5.2.2 Detecção de Regiões

O método de segmentação baseado em regiões tem como objetivo obter um determinado grupo de regiões, que correspondem aos objetos de interesse que aparecem na imagem usando os valores dos pixels e as propriedades espaciais da imagem (GONZALEZ, 2000). A mais simples dessas abordagens é a agregação de pixels, que começa com pontos “sementes” e, a partir deles, crescem as regiões, anexando a cada ponto semente, aqueles pixels que possuam propriedades similares (como nível de cinza, textura ou cor). Há três passos importantes nesse algoritmo: a seleção de uma semente que represente adequadamente a região de interesse, a seleção de propriedades apropriadas para a inclusão de pontos na região durante o processo de crescimento e o estabelecimento de uma condição de parada. A seleção de um ponto como semente é baseada frequentemente em uma característica geral da imagem, como por exemplo, o ponto mais claro ou mais escuro (PIRES, 2006).

3.5.2.3 Detecção de contornos

Os algoritmos de segmentação baseados na detecção de contornos realizam a busca de pixels correspondentes às fronteiras entre as regiões, e quando esta é localizada, identificam as distintas regiões separadas por dadas fronteiras. O objetivo é encontrar discontinuidades na imagem, ou seja, pixels nos que destaquem a homogeneidade dado que seu tom de cinza varie bruscamente quando comparado ao de seus vizinhos.

A detecção de pontos de contorno pode ser feita usando operadores direcionais (gradiente), o Laplaciano e os diferenciais parciais. Os operadores de gradiente são vectores cuja direção indica os locais nos quais os níveis de cinza sofrem maior variação. O gradiente de uma imagem I no ponto (x, y) está baseado na primeira derivada dessa imagem como indica a Equação 11.

$$\nabla I(x, y) = \frac{\partial I(x, y)}{\partial x} \vec{i} + \frac{\partial I(x, y)}{\partial y} \vec{j} \quad (\text{Equação 11})$$

onde \vec{i} e \vec{j} são vectores unitários nas direções x e y , respectivamente. Assim uma variação rápida ao longo do eixo x e lenta ao longo da direção y indica a presença de uma borda praticamente vertical. Na detecção de bordas a magnitude e a direção do vector gradiente são

medidas importantes, porque delas vai depender o custo computacional requerido para sua solução.

A detecção de contornos também pode ser obtida observando a segunda derivada, dado que os pontos que pertencem à borda serão aqueles onde o laplaciano muda de sinal. Assim se define o Laplaciano aplicado numa imagem I no ponto (x, y) conforme Equação 12.

$$\nabla^2 I(x, y) = \frac{\partial^2 I(x, y)}{\partial x^2} + \frac{\partial^2 I(x, y)}{\partial y^2} \quad (\text{Equação 12})$$

Dado que o operador baseado na segunda derivada é extremadamente sensível ao ruído, para minimizar esse efeito se aplica um filtro gaussiano na imagem original antes de aplicar o laplaciano.

Tanto o filtro gradiente quanto o filtro laplaciano, costumam ser aproximados por máscaras de convolução ou operadores 3x3. Alguns exemplos destas máscaras são os operadores de Roberts, Prewitt e Sobel, os quais se apresentam na Tabela 1.

Tabela 1. Mascara dos operadores para detecção de contornos.
Fonte: GONZALEZ, 2010.

Operador	Vertical	Horizontal
Roberts	$\begin{bmatrix} -1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$	$\begin{bmatrix} 1 & 0 & 0 \\ 0 & -1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$
Prewitt	$\begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}$	$\begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix}$
Sobel	$\begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$	$\begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & -2 & -1 \end{bmatrix}$

O operador de Roberts calcula as diferenças entre os níveis de cinza em uma direção de 45°. Diferente do operador de Roberts, o operador de Prewitt diferencia os níveis de cinza nas direções vertical e horizontal, e suaviza o ruído da imagem. Por ser uma máscara com dimensão 3x3 há uma melhora significativa na detecção das bordas em relação ao operador de Roberts. O operador de Sobel é similar ao operador de Prewitt, porém com mais peso aos pontos próximos ao pixel central, por esse motivo a máscara de Sobel obtém as bordas mais destacadas em relação ao operador de Prewitt (GONZÁLEZ, 2000).

3.5.2.4 Análise textura

A análise de textura é uma técnica para avaliar a posição e as características da intensidade dos pixels e a intensidade de nível de cinza das imagens digitais. Características de textura são parâmetros matemáticos, calculado a partir da distribuição de pixels. De acordo com os métodos utilizados para avaliar as inter-relações de pixels, as três principais abordagens utilizadas na classificação de imagens para descrever texturas são estatística, estrutural e espectral (GONZALEZ, 2000). Eles são descritos como segue:

- Abordagem Estatística: a textura é definida por um conjunto de medidas locais padrões. As medidas incluem a entropia estatística comum, correlação, contraste e variância;
- Abordagem Estrutural consiste em usar a ideia de que as texturas são compostas por primitivas dispostos aproximadamente regular de acordo com regras bem definidas. Como exemplo, pode-se citar a descrição da textura com base em linhas paralelas espaçadas regularmente;
- Abordagem Espectral que é baseado nas propriedades do espectro de Fourier, sendo utilizados principalmente na frequência global, identificando os picos no espectro de energia elevada para a detecção de imagem.

A análise de textura utilizando abordagens estatísticas obtidas a partir de atributos extraídos da Matriz de Co-ocorrência de níveis de cinza (*Gray Level Co-occurrence Matrix – GLCM*), que é um método estatístico que fornece relações espaciais entre os níveis de cinza de imagens, permitindo a extração de atributos que representam características de textura, como rugosidade, granularidade e regularidade (CASTELLANO, 2004). O objetivo é encontrar uma regra de decisão probabilística associando textura das grades e definindo, assim, se a visibilidade é possível.

A GLCM é uma matriz de duas dimensões, gerada pela contagem de ocorrências de combinações de níveis de cinza do pixel e o seu pixel vizinho. Para cada uma das combinações possíveis entre um pixel e os seus vizinhos, cria-se um elemento na matriz de co-ocorrência, de modo que o tamanho da GLCM é $t \times t$, em que t é o número de níveis de cinza presente na imagem original (BLIZNAKOVA, 2009). Um elemento da matriz na posição (i, j) indica quantas vezes na imagem original de um par de níveis de cinza de pontos (i, j) é dado, separados pela distância definida (δ) e numa direção escolhida (θ).

Para ilustrar o método, a Figura 11 mostra o processo para a obtenção da matriz de co-ocorrência níveis de cinza. Em uma imagem de tamanho 4×4 , $t = 4$ níveis de cinza, as

matrizes de co-ocorrência são de tamanho 4 x 4. Considerando $\theta = 0^\circ$ e $\delta = 1$ neste exemplo, portanto, a posição (0,1) é equivalente à quantas vezes o nível de cinza 0 aparece em relação ao nível de cinza 1 a uma distância 0 graus, na GLCM mostra que esta relação ocorre duas vezes na imagem.

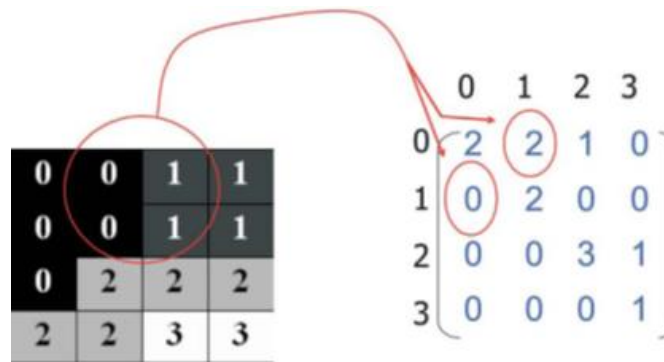


Figura 11. Gray Nível Matrix e GLCM.
Fonte: MATHWORKS, 2012.

Os atributos de textura extraídos de GLCM com base nas características de Haralick podem ser descritas em até 14 descritores diferentes (HARALICK, 1979) da seguinte forma: energia (uniformidade), contraste, correlação, momento da diferença inverso, soma significativa, diferença média, entropia, entropia da soma, diferença de entropia, variância da soma da diferença variância e correlação ação de informação. Os principais descritores de textura são mostrados na Tabela 2, com as suas características e o tipo de informação obtida a partir de cada um deles.

Tabela 2. Características dos atributos de textura.
Fonte: Acervo do Autor

Estatísticas	Equações	Descrição e informação obtida.
Contraste	$C = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P(i,j)(i-j)^2$	Mede as variações locais da GLCM. Devolve uma medida do contraste entre as intensidades de um pixel e o seu pixel vizinho. Para uma imagem constante (mesmos níveis de cinza em toda sua extensão) o contraste é 0 (zero).
Correlação	$c = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} P(i,j) \left[\frac{(i - \mu_i)(j - \mu_j)}{(S_i)(S_j)} \right]$	Mede a probabilidade de ocorrência conjunta dos pares de pixel específicos. Faixa dos possíveis valores: -1 a 1

Energia	$En = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} [P(i,j)]^2$	<p>Também conhecida como a uniformidade ou o segundo momento angular.</p> <p>Retorna a soma dos quadrados elementos dentro GLCM.</p> <p>Faixa de valores possíveis: 0 a 1</p> <p>A energia tem um valor de 1 para uma imagem constante (mesmos níveis de cinza em toda a imagem).</p>
Homogeneidade	$H = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} \frac{P(i,j)}{1 + (i-j)^2}$	<p>Retorna um valor que representa a proximidade da distribuição dos elementos em relação à diagonal do GLCM.</p> <p>Faixa de valores possíveis: 0 a 1</p>
Entropia	$E = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} \log(P(i,j))P(i,j)$	<p>Fornecer o grau de dispersão dos níveis de cinza na imagem, medindo as informações contidas no pixel. Muitos pixels com o mesmo valor de nível de cinza significa uma imagem com pouca informação ou pequeno entropia.</p>

Sendo $P(i, j)$ os elementos da Matriz de co-ocorrência de níveis de cinza obtida da imagem.

3.5.3 Pós-Processamento

Em algumas ocasiões depois do processo de segmentação é necessário corrigir algumas das imagens binárias resultantes, como a separação de objetos que se tocam ou agrupamento de regiões fragmentadas. Estes procedimentos são implementados geralmente através de operações morfológicas matemáticas. A morfologia matemática é composta por uma série de técnicas matemáticas que permitem a análise da forma dos objetos, com a finalidade de extrair as características úteis para sua identificação e classificação.

As duas transformações mais comuns da morfologia matemática, que são baseadas em outras transformações morfológicas complexas, são a *erosão* e a *dilatação*. Cada operação de erosão e dilatação utiliza uma determinada vizinhança. Essa vizinhança é representada por um “elemento estrutural” que corresponde a uma matriz de zeros e uns. Um elemento estrutural pode ter qualquer tamanho ainda que sua dimensão mais habitual seja de 3x3 (Fig. 12).

S_{11}	S_{12}	S_{13}
S_{21}	S_{22}	S_{23}
S_{31}	S_{32}	S_{33}

Figura 12. Elemento estrutural de dimensões de 3x3, pixel central S_{22} .
Fonte: Acervo do autor.

Para determinar a ação da erosão e a dilatação sobre uma imagem binária de entrada, I , se fixa um pixel na imagem I , denominado pixel de interesse, $I(x,y)$, sob esse pixel se superpõe o elemento estrutural fazendo coincidir o pixel central sob o pixel de interesse (Fig. 13).

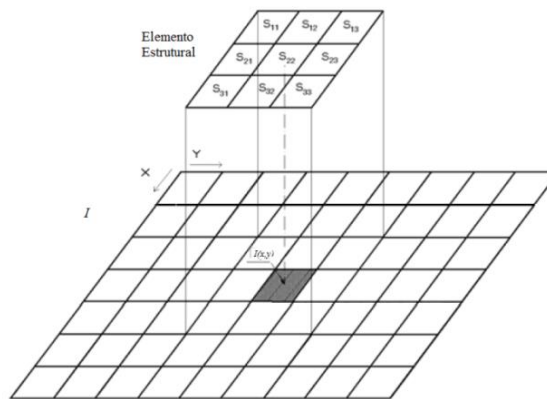


Figura 13. Modo de operação do elemento estrutural sob a imagem I .
Fonte: MATHWORKS, 2012.

O efeito que produz uma erosão nos objetos da imagem binária consiste em eliminar os objetos selecionados na capa exterior de pixels, ou seja, aqueles em contato com o fundo. A erosão faz com que diminua o tamanho dos objetos incluindo fazê-los desaparecer caso em que eles sejam menores e o elemento estrutural não fique dentro dele. A dilatação é o caso contrário, consiste em adicionar aos objetos da imagem uma capa extra de pixels. A dilatação aumenta o tamanho dos objetos, fecha agulheiros de um objeto que seja suficientemente pequeno ou diminui seu tamanho, podendo unir dois objetos muito próximos, inicialmente separados (MATHWORKS, 2012).

A Figura 14 apresenta as imagens binárias produzidas depois de aplicar uma Erosão (Fig. 14b) e uma dilatação (Fig. 14c) na capa externa dos pixels a uma imagem binária original (Fig. 14a).




Figura 14. (a) Imagem binária inicial. (b) Imagem binária com Erosão. (c) Imagem binária dilatada.
Fonte: MATHWORKS, 2012.

Outros operadores morfológicos são os de *abertura* e *fechamento* que estão baseados na aplicação sequencial dos operadores erosão e dilatação. A abertura se define como uma erosão seguida de uma dilatação e o fechamento é a operação inversa à abertura, definido como uma dilatação seguida de uma erosão.

A vantagem desses operadores é que eles mantêm aproximadamente constante o tamanho dos objetos e, além disso, a abertura elimina pequenas estruturas asiladas que saem do objeto e separa os objetos unidos pelos istmos, enquanto que o fechamento elimina pequenos agulheiros. Existem outros operadores morfológicos importantes, porém não são utilizados nesse estudo como: o afinamento e espessamento, a extração do esqueleto do objeto, entre outras (FILHO, 1999).

3.6 Simuladores de mama

Para garantir que os mamógrafos produzem imagens com qualidade diagnóstica, os simuladores utilizados na avaliação da qualidade das imagens mamográficas contêm recursos tais como fibras, grupos de microcalcificações e as massas que simulam lesões de interesse durante a mamografia. Um simulador adequado deve ser capaz de indicar alterações na qualidade da imagem em todo conjunto de fatores técnicos esperados na prática clínica (PEREIRA, 2013).

Entre os principais simuladores de mama estão o phantom acreditado pelo Colégio Americano de Radiologia (*American College of Radiology -ACR*), o phantom CIRS SP01 (*Computerized Imaging Reference System Inc.- CIRS*), os simuladores phantom TOR[*MAX*], TOR[*MAM*] e TOR[*MAS*] desenvolvidos na Universidade de Leeds no Reino Unido e o *Phantom mama* reconhecido pelo Colégio Brasileiro de Radiologia (CBR). Esses simuladores

são utilizados na avaliação da qualidade da imagem em mamografia na tarefa de detecção de lesões simuladas na mama. (TOMAL, 2009). O phantom mama é um dos mais utilizados no Brasil pela facilidade de aquisição dado que não precisa importação e seu preço é menor.

3.6.1 Parâmetros de avaliação da qualidade da Imagem usando o Phantom Mama.

O *Phantom mama* constituído por placas acrílicas que simulam uma mama comprimida de 5 cm de espessura, e composição (50% de tecido glandular e 50% do tecido adiposo). É formado por três placas de plexiglass (Polimetilmetacrilato - PMMA) de 10 x 120 x 160 mm³, e uma placa de 20 x 120 x 160 mm³. Esta última placa contém uma cera inserida com volume de 5 x 70 x 140 mm³; esta placa tem também uma cunha que produz na imagem cinco densidades ópticas, utilizadas para avaliar o contraste da imagem, isso definido para imagens analógicas (Fig. 15).



Figura 15. *Phantom mama* reconhecido pelo Colégio Brasileiro de Radiologia.

Na cera inserida na placa são incorporados as seguintes estruturas:

- Quatro grades de metal que representam a resolução espacial de 4, 6, 8 e 12 lp/mm (G1 a G4);
- Cinco grupos de grãos de Al₂O₃ de 0.45, 0.35, 0.30, 0.25 e 0.18 mm de diâmetro (μ1 a μ5) para simular microcalcificações;
- Oito discos de poliéster com 6 mm de diâmetro, com espessura variando de 0,1 a 0,8 mm (D1 a D8) para simular áreas de baixo contraste;
- Seis fibras de nylon, com 1 cm de comprimento e 1,4, 1,2, 0,8, 0,7, 0,6 e 0,4 mm de diâmetro (F1 a F6) para simular fibras; e

- Cinco calotas esféricas de nylon de 2,0, 1,5, 1,0, 0,75 e 0,50 mm alturas (M1 a M5) para simular tumores uniformes (OLIVEIRA, 2007).

Um diagrama esquemático do *Phantom mama* (Fig. 16) apresenta cada uma das categorias dos objetos de teste, o tamanho e/ou o contraste de objetos diminui gradualmente. Por exemplo, $\mu 1$ representa o grupo de microcalcificações contendo os maiores grãos e $\mu 5$ os menores, com uma convenção semelhante para as demais estruturas. No caso das grades, a primeira grade (G1) representa uma menor quantidade de pares de linhas por milímetro (~ 4 lp/mm) equivalente a uma menor resolução espacial enquanto a quarta grade (G4) representa a maior quantidade de pares de linhas por milímetro (~ 12 lp/mm).




Figura 16. Diagrama esquemático do *Phantom mama*.
Fonte: PEREIRA, 2013.

A metodologia sugerida pela Vigilância Sanitária para avaliar a qualidade da imagem consiste em avaliar visualmente a imagem radiográfica obtida do simulador analisando a definição de resolução espacial, detalhes de alto contraste, limiar de baixo contraste, detalhes lineares de baixo contraste (tecido fibroso), massas tumorais e, com o auxílio do densitômetro a densidade ótica (INCA, 2004). Os limites de aceitação para os testes aplicados pela VISA-MG são:

1. Definição da imagem (resolução espacial): O valor de aceitação da resolução espacial deve ser maior que 12 lp/mm, ou seja, as quatro grades metálicas devem ser visualizadas com definição para imagens obtidas com sistema analógico de imagem.
2. Detalhes de alto contraste (grupos de microcalcificações): O *phantom mama* tem cinco grupos, para a aceitabilidade da imagem deve-se visualizar até o conjunto de microcalcificações de 0,25 mm correspondente ao quarto grupo de microcalcificações ($\mu 4$).

3. Limiar de baixo contraste (Discos): O percentual de variação do contraste é estabelecido em função da densidade ótica (DO) das regiões do filme dentro e fora dos discos de poliéster. Com o auxílio de um densitômetro avalia-se o limiar de baixo contraste em porcentagem. Para ser aprovado neste teste sugere-se 1,5% como limiar de contraste para discos de 5 mm de diâmetro, o sétimo disco (D7).
4. Detalhes lineares de baixo contraste (tecido fibroso): Quando o simulador é radiografado, esses detalhes lineares de baixo contraste permitem a medida da sensibilidade do sistema de produção da imagem em registrar estruturas filamentosas no interior da mama. Na avaliação se registra o menor diâmetro da fibra visualizada. Para aprovação neste teste é necessário visualizar mínimo a quarta fibra (F4).
5. Massas tumorais: O simulador de mama dispõe de calotas esféricas de nylon que simulam massas tumorais. Essas calotas possuem diâmetros e alturas variadas. Quando o simulador é radiografado estas calotas esféricas produzem uma série de imagens bastante similares às massas tumorais mamárias. Para aprovação neste teste é necessário visualizar até a massa de 0,75 mm de altura (M4).

Parâmetros adicionais podem ser propostos nesse trabalho para serem avaliados nas imagens do simulador, como é a Razão Contraste-Ruído para avaliar o limiar de contraste. Esse teste pode ser aplicado na imagem sob as estruturas que representam os discos. A CNR depende do ruído, do número de bits utilizados na discretização do sinal (profundidade do pixel), da diferença nos sinais associados ao detalhe de interesse e ao tecido em que este detalhe se encontra (CHEVALIER, 2010; GENNARO, 2007).

3.7 Programa de Monitoramento Mensal da Qualidade da Imagem

A importância do controle de qualidade em sistemas de radiologia diagnóstica tem sido muito reconhecida devido à necessidade de garantir a confiabilidade do exame executado para produzir uma imagem que apresente as características necessárias para o correto diagnóstico médico. Com o objetivo de oferecer à população feminina do Estado de Minas Gerais exames de mamografia dentro dos padrões de qualidade necessários para a detecção precoce do câncer de mama e, conseqüentemente, reduzir a mortalidade por este tipo de câncer, a Secretaria de Estado de Saúde de Minas Gerais (SES-MG), através da Superintendência Estadual de Vigilância Sanitária, criou, em 2004, o Programa Estadual de Controle de Qualidade em Mamografia – PECQMamo (MINAS GERAIS, 2013).

Como resultado do programa PECQMamo, a Secretaria de Estado de Saúde de Minas Gerais instituiu, através da Resolução SES/MG nº 1356, de 20 de dezembro de 2007 (Minas Gerais, 2007), o Programa de Monitoramento Mensal da Qualidade dos serviços de mamografia públicos e privados do Estado por meio da avaliação da imagem radiográfica de um simulador de mama. Assim cada serviço de mamografia monitorado envia mensalmente à Diretoria de Vigilância em Serviços de Saúde (DVSS) uma radiografia de um simulador de mama. As imagens recebidas são avaliadas visualmente de acordo com os critérios definidos na Portaria SVS/MS nº 453/98, no Guia da ANVISA “Radiodiagnóstico Médico, Segurança e Desempenho de Equipamentos” (BRASIL, 1998).

O Fluxo do processo de monitoramento mensal é executado em basicamente cinco etapas:

1. O serviço encaminha a Ficha de Cadastro Inicial para Avaliação Mensal – FCIAM e a DVSS cadastra ou/atualiza o cadastro no Sistema de Informação ATALANTA.
2. A DVSS divulga o código mensal para ser radiografado junto ao simulador;
3. O serviço faz a aquisição da imagem com o código mensal radiografado e a encaminha para a DVSS;
4. A DVSS avalia a imagem e solicita a 2ª imagem, quando for o caso seja não aprovada a imagem ou algum caso especificado no programa;
5. A DVSS divulga os resultados no site ATALANTA (www.atalanta.cdtm.br), e ficam disponibilizados para o público.

Na quarta etapa a avaliação da imagem é feita visualmente, o que leva a denominações subjetivas nos resultados. Este trabalho visa criar ferramentas e aplicá-las com o intuito de diminuir a subjetividade da avaliação, além de agilizar o grande volume de imagens que devem ser avaliados, número que poderia aumentar se for efetivado a expansão do Programa a todo o Estado. Até o momento o programa é feito somente na região metropolitana de Belo Horizonte, capital do Estado.

3.8 Análises Estatísticas

O coeficiente Kappa (κ), descrita em 1960 por Cohen, é uma medida de concordância intra e inter-observador (COHEN, 1960). O coeficiente Kappa fornece uma medida do grau em que dois juízes concorrem nos N itens de ordenações dentro de k em categorias mutuamente exclusivos. Um "juiz" neste contexto pode ser um ser humano individual (ou um conjunto de indivíduos) que classifica os N itens, ou algum organismo não humano, tal como um

programa de computador ou teste de diagnóstico, que realiza uma classificação com base num especificado critério (VASSARSTAT, 2016).

O Kappa adota um valor entre -1 e + 1, sendo +1 o grau mais forte de concordância inter-observadores. O coeficiente Kappa é calculado a partir da Equação 13.

$$\kappa = \frac{P_0 - P_E}{1 - P_E} \quad (\text{Equação 13})$$

Onde P_0 é a razão entre o número de concordâncias por número total de observações e P_E é o número de concordâncias esperadas, calculadas com a expressão da Equação 14.

$$P_E = \sum_{i=1}^n (p_{i1} \times p_{i2}) \quad (\text{Equação 14})$$

sendo que: n é o número de categorias; i é o índice da categoria (que vale de 1 a n); p_{i1} é a proporção de ocorrência da categoria i para o avaliador 1; p_{i2} é a proporção de ocorrência da categoria i para o avaliador 2.

A interpretação do Coeficiente Kappa é realizada por meio da correlação de seu valor com uma escala qualitativa, que inclui seis níveis de força de contrato. A Tabela 3 corresponde à escala qualitativa frequentemente utilizada para expressar a força de concordância (LANDIS, 1977).

Tabela 3. Avaliação do Coeficiente Kappa.
(Landis and Koch, 1977).

Kappa (κ)	Força de concordância
< 0,00	Pobre
0,01 – 0,20	Leve
0,21 – 0,40	Considerável
0,41 – 0,60	Moderado
0,61 – 0,80	Substancial
0,81 – 1,00	Quase perfeita

Por sua vez, o erro padrão da estatística k permite-nos estimar a sua significância estatística e também o seu intervalo de confiança de 95%.

4. ESTADO DA ARTE

Diferentes autores têm desenvolvidos programas para obter a análise da avaliação da imagem de outros simuladores de mama utilizados no controle de qualidade dos equipamentos de mamografia.

Chakraborty e Eckert (1995) compararam leituras visuais de imagens com uma análise computadorizada, usando o phantom ACR Modelo RMI 156 que contém três estruturas como microcalcificações, massas e fibras. Oito observadores analisaram 27 imagens digitalizadas, indicando quantos objetos testes eram completamente visíveis, e quantos que eram parcialmente visíveis. Em seguida, eles usaram a linguagem de programação C e MATLAB para as avaliações computadorizadas medindo o valor médio de pixels e o nível de ruído de fundo numa região do phantom, além do contraste relativo. Os resultados mostraram que a precisão aumenta usando a imagem depois de processamento computadorizado em um ganho de um fator de 9. Alguns anos depois Chakraborty (1997) estendeu o trabalho anterior com a aplicação de análise por computador de imagens de mamografia (*Computer Analysis of Mammography Phantom Images -CAMPI*) usando 32 imagens digitais do phantom do ACR adquiridas no equipamento de Fischer Mammotest. Grupos de microcalcificações foram avaliados e várias medições foram feitas, tais como contraste nas imagens e a visualização da forma das microcalcificações. Os resultados mostraram que a precisão das medidas CAMPI foram maiores do que os observadores humanos.

No mesmo ano Brooks e seus colaboradores (1997), demonstrou que análises computadorizadas da imagem do phantom acreditado americano pode ser objetiva uma vez que um nível de aceitação humana seja estabelecido. Eles analisaram doze imagens digitalizadas, dezenove físicos médicos definiram as pontuações das estruturas detectadas. Usando técnicas de Fourier combinado com filtros derivativos desenvolveram algoritmos para a detecção das três estruturas fibras, nódulos e microcalcificações. Estabeleceram critérios de decisão para a visibilidade pelas respostas dos observadores. Usando esses valores para estimar o desempenho humano e dada a localização dos objetos no teste computacional, seis imagens foram classificadas pelo algoritmo computacional. Em todos, exceto num caso, o algoritmo teve as imagens da mesma como os físicos. No caso em que isso não aconteceu, a margem de desacordo foi de 10%, devido ao fato de que a acuidade humana não permitia fibrilas semivisíveis (acordos ocorreram para os outros objetos de teste).

Dougherty (1998) aplicou técnicas de processamento de imagem com o propósito de estabelecer uma metodologia que seria sensível às condições de exposição e discriminatório

entre os diferentes sistemas de aquisição imagem. Foi usado o phantom acreditado RMI Modelo 156 e as imagens foram obtidas com um equipamento de mamografia Senographe da General Electric; e essas imagens foram posteriormente digitalizadas em um sistema CR. Nas imagens foram selecionadas as ROIs contendo nódulos e microcalcificações, logo foram computadas as características de contraste e fundo. A avaliação foi realizada comparando a análise dos filmes por cinco observadores, e os resultados fornecidos computacionalmente; as métricas numéricas apontavam a possibilidade de automação do sistema de controle de qualidade de imagem.

Outros autores como Castellano e seus colaboradores (1998) tiveram como objetivo desenvolver um método objetivo da avaliação da qualidade de imagem, a fim de remover as variações inter-observador do processo de pontuação dos objetos teste. Eles utilizaram dez filmes do phantom TOR(MAX) de Leeds e de diferentes sistemas de aquisição de imagens foram avaliados por cinco físicos experientes e comparados com os algoritmos desenvolvidos. As regiões de interesse (ROI) escolhidas para este estudo foram circulares usada na localização inicial, nas grades de alto e de baixo de contraste, de 6 mm/ 0.25 mm/ 0.5 mm de diâmetro. Nesse estudo os autores afirmaram que é necessário ao longo do tempo estabelecer restrições na utilização da técnica para a digitalização dos filmes, e que os algoritmos não responderam bem em algumas ROIs enquanto que em outras, era parcialmente bem sucedida. Mais estudos são necessários a fim de representar apropriadamente imagens

Blot e seus colaboradores (2002) utilizaram técnicas de análise de textura para detectar e contabilizar grupos de micropartículas como objeto de teste do phantom Leeds TOR(MAM). Foram obtidas 16 imagens digitais do phantom e a partir delas seis grupos das micropartículas foram extraídas e contabilizadas por dois observadores. Após estas extrações, o método automatizado computadorizado envolveu a extração das características de cada ROI, baseado na matriz cinza de co-ocorrência de níveis de cinza e a pontuação das características detectadas usando um método de classificação estatística, o vizinho k mais próximo. Os resultados mostraram um acordo de 82% entre o método automatizado e o observador experiente, indicando a viabilidade de um método para o controle de qualidade em imagens do phantom de mamografia.

Com o objetivo de identificar as microcalcificações, resolução de imagem e densidade óptica, Mayo e seus colaboradores (2004), usaram cinco imagens digitalizadas do phantom do CIRS modelo 11-A, SP01 As imagens foram obtidas do mesmo equipamento de mamografia sob diferentes condições clínicas. As radiografias foram digitalizadas com uma resolução de

1200 dpi. Para cada grupo de microcalcificações presentes na imagem do phantom foram realizadas três etapas no processamento da imagem digital: a limiarização, um crescimento da região, e aplicações de operadores morfológicos; os resultados confirmaram que o algoritmo funcionou bem para a identificação dos objetos teste. A resolução de imagem consistia na identificação de 16 grupos de linhas verticais e 16 horizontais, onde limiar e um operador morfológico foram empregados para as imagens. Os testes estatísticos foram realizados para verificar a correlação dos valores e verificou-se que a resolução pode ser usada como uma medida da qualidade da imagem. Finalmente, a densidade óptica com uma correspondência de 100% de densidade de tecido adiposo e 100% de densidade de tecido glandular foi caracterizada pelo valor do sinal-ruído (SNR). Este valor é sempre mais elevado para o tecido glandular e um melhor resultado pode ser obtido quando uma resolução mais alta é usada. Os autores concluíram que a resolução óptica do scanner é um fator influente no que poderia afetar o processamento de resultados mais precisos e definiram que 1200 dpi seria uma escolha adequada para este trabalho.

Outras comparações entre uma avaliação visual e computadorizada de imagens do phantom acreditado da ACR Modelo RMI 156 foi desenvolvido por Lee e seus colaboradores (2010). Eles digitalizaram 51 imagens do simulador que foram analisadas por um físico médico e dois técnicos de radiologia, a fim de serem comparadas com a avaliação computadorizada. O método do processamento digital consistiu na subtração de fundo (algoritmo rolling-ball), a determinação das ROIs, classificação de fibras e objetos de massa (contraste e distância de Mahalanobis), e a detecção das microcalcificações. Após essas detecções, a avaliação foi realizada com base nos critérios do ACR. A precisão obtida desta avaliação computadorizada foi de 90%, 80%, e 98% para fibra, massa e microcalcificações, respectivamente. No entanto, a concordância entre os observadores e avaliação computadorizada tem associação significativa para microcalcificações, mas não para massas e fibras.

No mesmo ano, Mayo e seus colaboradores (2010), utilizaram dois phantom de mamografia, CIRS SP01 e RACON, a fim de analisar a qualidade de imagem de um modo automático. Alguns algoritmos específicos, implementados usando MatLab, foram aplicados as subimagens, como filtros para remoção de ruído, reconhecimento de padrões, detectores de bordas, limiarização, e operadores morfológicos. Os objetos de teste foram detectados pelo software desenvolvido, indicando sua utilidade para o controle de qualidade do equipamento.

A tabela 4 apresenta um resumo de trabalhos de diversos autores usando uma análise de computadorizado de imagens de simuladores de mama, qual foi o phantom usado, número

de imagens estudadas, o tipo de estruturas visualizadas e número de avaliadores visuais no caso que tenha avaliação visual das imagens (Tab. 4).

Tabela 4. Resumo de trabalhos publicados usando uma análise de computadorizado de imagens do phantom de mamografia.

Autor (ano)	Phantom	No de Imagens	Estruturas Visualizadas	Avaliação Visual – No de avaliadores
Chakraborty <i>et al.</i> (1995)	ACR RMI 156	27	Fibras, microcalcificações, nódulos.	Sim – 8
Chakraborty <i>et al.</i> (1997)	Digital ACR	32	Microcalcificações	Não
Brooks <i>et al.</i> (1997)	ACR RMI 156	12	Fibras, microcalcificações, nódulos.	Sim – 19
Castellano (1998)	Leeds TOR(MAX)	10	Contraste, detalhes circulares	Sim – 5
Dougherty <i>et al.</i> (1998)	ACR RMI 156	-	Nódulos, Microcalcificações	Sim – 5
Blot <i>et al.</i> (2002).	Leeds TOR(MAM)	16	Macro partículas	Sim – 2
Mayo <i>et al.</i> (2004)	CIRS modelo 11-A, SP01	5	Microcalcificações, Resolução, Densidade Ótica.	Não
Lee <i>et al.</i> (2010)	ACR RMI 156	51	Fibras, Massas, Microcalcificações	Sim – 3
Mayo <i>et al.</i> (2010)	CIRS SP01 e RACON	2	Todos os objetos teste	Não

5. MATERIAIS E MÉTODOS

5.1 Amostragem e Equipamentos

Foram coletadas aleatoriamente do banco de dados da VISA-MG, 50 radiografias de imagens do *Phantom mama* enviadas por instituições vinculadas ao Programa de Monitoramento Mensal. As radiografias foram digitalizadas no scanner ScanMaker 9800XL da marca Microtek (Fig. 17).



Figura 17. Scanner ScanMaker 9800XL.
Fonte: Acervo do autor.

Também foram usadas imagens adquiridas no mamógrafo de pesquisa MAMMOMAT 3000 Nova fabricado pela Siemens (Fig. 18a) cujas especificações técnicas são apresentadas na Tabela 5.

Tabela 5. Características técnicas do mamógrafo MAMMOMAT 3000 Nova.

Componente	Descrição
Ânodo (giratório)	Molibdênio e Tungstênio
Filtros	Molibdênio (30 μm) Ródio (25 μm e 50 μm)
Combinações anodo/filtro	Mo/Mo, Mo/Rh e W/Rh
Tensão (kV)	23 - 35
Carga (mAs)	2 - 752
Tempo de exposição	10 ms – 7 s
Tamanho do ponto focal	0.1/ 0.3
Filtração inerente (mm Be)	1,0
Distância Fonte/Receptor (cm)	65

Para processar a imagem foi usado um sistema de radiografia computadorizada- CR, que utiliza placas de fósforo modelo EHR-M2 *kodak DirectView CR Mammography Cassete*. As imagens são digitalizadas na processadora de imagem modelo *Kodak DirectView 850 System*

(Fig. 18b). Todos esses equipamentos pertencem ao Laboratório de Radioproteção aplicado a Mamografia (LARAM) instalado no Centro de Desenvolvimento de Tecnologia Nuclear (CDTN).

O mamógrafo utilizado foi um equipamento de pesquisa, que passa frequentemente pelos testes de constância de controle de qualidade, entre eles o teste de rendimento do equipamento e taxa de dose. Os resultados de rendimento e taxa de dose foram de $3,57 \mu\text{Gy/mAs}$ a 1 m de distância e $2,8 \text{ mGy/s}$ a 65 cm de distância com 28 kVp.



Figura 18. (a)Mamógrafo SIEMENS, Mammomat 3000 Nova. (b) Processadora de imagem modelo Kodak DirectView 850 System.
Fonte: Acervo do Autor

Para a aquisição das imagens no sistema CR disponível no LARAM, o *phantom mama* foi posicionado sobre o suporte da mama e sob a bandeja de compressão, centralizado lateralmente (Fig. 19). As irradiações foram feitas utilizando diferentes parâmetros de aquisição como Tensão do tubo: 24, 26, 28, 30 e 32 kVp.

Para cada Tensão foram feitas imagens, utilizando valores de Carga diferentes (20, 80, 125 mAs); e isso para cada uma das três combinações ânodo/filtro disponíveis (Mo/Mo, Mo/Rh e W/Rh).




Figura 19. Posicionamento do *Phantom mama* para aquisição das imagens.
Fonte: Minas Gerais, 2013.

As imagens foram salvas com processamento em formato DICOM. Todas as imagens têm tamanho da matriz de 3584 x 4784 pixels, 65536 tons de cinza (imagem 16-bit; $L = 2^{16}$). O tamanho de pixel das imagens é de 50 μm e o tamanho para armazenamento da imagem é 33,5 MB. Definiu-se como imagem padrão aquela adquirida com parâmetros mais próximos à prática clínica (28 kV, 125 mAs, Mo/Mo) (Fig. 20).




Figura 20. Imagem padrão
Fonte: Acervo do Autor

5.2 Avaliação por observadores humanos

Para avaliação visual das imagens radiográficas do banco de dados da VISA, foi utilizado um negatoscopio específico para mamografia (luminância $>3000 \text{ cd/m}^2$) (Fig. 21).



Figura 21. Negatoscopio Planilux Modelo DXHM 72X46cm
Fonte: Acervo do Autor.

As imagens adquiridas no mamógrafo do LARAM/CDTN foram avaliadas em um monitor específico para laudo, da marca Planar, modelo GX5MP (Fig. 22), com resolução de 5 Mega Pixels.




Figura 22. Monitor específico para laudos de mamografia de 5 MP,
Fonte: Acervo do autor.

Para a avaliação visual, as 50 imagens do banco de dados da VISA-MG foram avaliadas em um negatoscópio por quatro avaliadores treinados que contabilizavam o número de

estruturas que era possível enxergar. Para avaliar às imagens obtidas no sistema CR três avaliadores definiram o número de estruturas visível para cada uma das imagens adquiridas nos diferentes parâmetros de exposição.

5.3 Avaliação computadorizada

Os algoritmos para o processamento de imagens digitais foram desenvolvidos utilizando o software MATLAB® R2012b (*Matrix Laboratory*), que é uma linguagem de alto nível e ambiente interativo para computação numérica, visualização e programação. A estrutura básica de dados em MATLAB é a matriz, um conjunto ordenado de elementos reais ou complexos. Este objeto é naturalmente adequado para a representação de imagens de valor real, ordenando um conjunto de dados de cor ou de dados de intensidade. Assim, as imagens são armazenadas como matrizes bidimensionais em que cada elemento da matriz corresponde a um único pixel na imagem exibida.

O programa foi instalado em um computador com processador Intel Core™ i3-2120 CPU@ 3,30 GHz e memória RAM 4,00 GB, com sistema operacional Windows 7 da Microsoft Corporation (64Bits).

Foi desenvolvida uma metodologia para a obtenção da avaliação automática das imagens do *Phantom mama* obtidas do banco de dados da VISA e foram feitas algumas modificações nos algoritmos para processamento das imagens obtidas no mamógrafo do LARAM.

Os 50 filmes do banco de dados da VISA-MG foram digitalizados com uma resolução de 1200dpi. O tamanho das imagens foi padronizado em imagens de 5800 x7700 pixels, com escala de cinza de 16 bits/pixel, ou seja, a escala de cinzas formada por 65625 valores e as imagens salvas em formato tif. Uma resolução de 1200 dpi é equivalente a um tamanho de pixel de 25 µm.

A resposta do scanner foi medida pelo parâmetro MTF (*Modulation Transfer Funtion*). Este parâmetro especifica a amplitude relativa do sinal de saída em função da frequência espacial (pl/mm) de um sinal de entrada senoidal. A MTF característica do scanner utilizado pode se aproximar conforme a Equação 15 (KOREN, 2016).

$$MFT(f) = \left| \frac{\sin\left(\frac{\pi \cdot f}{dscan}\right)}{\left(\frac{\pi \cdot f}{dscan}\right)} \right|^3 \quad \text{se } f \neq 0 \quad (\text{Equação 15})$$

onde $dscan$ é a resolução do escaner em pix/mm e f é a frequência espacial (pl/mm). Usando essa aproximação, as frequências espaciais correspondentes a 5% e 10% da MTF foram 17.3 e 29.8 pl/mm com a imagem de 1200 pdi.

Cada região do *Phantom mama* requer um tratamento particular. A imagem do *Phantom mama* foi dividida em sub-imagens chamadas de Regiões de Interesse (ROI). Para que essa divisão seja feita de forma automática, o tamanho das ROIs selecionadas foi suficiente para que pequenas mudanças no posicionamento do *phantom* na obtenção da imagem não alterem a localização das ROIs e estas não coincidam depois de ser digitalizadas. Consideram-se regiões de interesse para este trabalho cada grupo de microcalcificações, as regiões que simulam massas, fibras e a região das grades metálicas.

A imagem uma vez digitalizada foi tratada como uma matriz I na qual o elemento $I(x,y)$ representa o tom de cinza correspondente ao pixel situado na linha x e coluna y . A origem de coordenadas foi fixada no canto superior esquerdo da imagem, de tal forma que o pixel situado nesse ponto é $I(1,1)$. A posição de um objeto na imagem é determinada dando as coordenadas dos pixels que ocupa. As técnicas empregadas no processamento da imagem digital do *Phantom mama* são técnicas reconhecidas no tratamento digital de imagens explicadas no capítulo anterior, tais como filtragem de imagens para a diminuição de ruído, limiarização da imagem para detectar objetos, aplicação de operadores morfológicos (abertura, fechamento, etc.), entre outros.

A evolução tecnológica dos detectores digitais levou a mamografia a passar de tela/filme para o digital (GENNARO, 2007). Um número cada vez maior de centros de diagnóstico tem adotado sistemas de aquisição de imagem o CR e/ou DR, em que as imagens podem ser disponibilizadas na tela dos computadores para a realização do laudo.

O crescente aumento no número de mamógrafos com sistema CR em relação aos mamógrafos convencionais em MG, somado as deficiências na aplicação de algoritmos gerais em todas as imagens adquiridas em diferentes equipamentos, fez necessário aplicar algumas modificações nos algoritmos para detecção de estruturas nas imagens adquiridas no sistema CR.

A seguir estão descritas as metodologias para a detecção de cada uma das estruturas e algumas modificações no caso que foram realizadas.

5.3.1 *Microcalcificações*

Na imagem esquemática do phantom (Fig. 16) estão demonstrados os grupos de microcalcificações denominados por μ_1 , μ_2 , μ_3 , μ_4 e μ_5 . O diâmetro das microcalcificações

de cada um dos grupos varia de um grupo a outro, sendo o grupo μ_1 o maior e vai diminuindo até o grupo μ_5 . Cada grupo está constituído por cinco microcalcificações dispostas em formato de uma cruz.

Como foi indicado, em cada grupo se formou uma ROI que foi denominada genericamente I , aplicando posteriormente o mesmo algoritmo a cada uma delas para extrair suas características mais importantes.

O primeiro passo na análise da ROI foi a filtração da imagem para remover parte do ruído gerado na aquisição da imagem, depois passou por um processo de segmentação com o objetivo de detectar e isolar cada uma das microcalcificações da imagem. A identificação das microcalcificações se realiza em várias etapas: limiarização, crescimento de regiões e aplicação de operadores morfológicos.

Uma filtragem adaptativa de remoção de ruído foi aplicada usando o Filtro Wiener (Função $wiener2(I, [m\ n])$), esse, filtra o pixel da imagem I utilizando a filtragem de Wiener adaptativo, usando a vizinhança de tamanho $m \times n$ para estimar a imagem local média e desvio padrão; nessa pesquisa foi utilizada uma vizinhança 3×3 .

Na etapa da limiarização foi aplicado um limiar na imagem para selecionar os pixels com tom de cinza maior que o limiar, selecionando assim as zonas mais brilhantes da imagem. A definição deste valor é muito importante dado que um limiar muito alto pode deixar de selecionar as microcalcificações que possuam menor contraste, enquanto que um limiar muito baixo pode permitir que selecionasse pontos brilhantes que não correspondam a nenhuma microcalcificação e que acontecem basicamente pelas oscilações nos tons de cinza do fundo e pelo ruído que contem a imagem.

Assim o valor do limiar foi estabelecido como 20% a mais do que o valor calculado automaticamente pela função de limiarização *graythresh*, que calcula um limite global (nível), que pode ser utilizado para converter uma imagem de intensidades em uma imagem binária com a função *im2bw*. O valor do limiar é um valor normalizado que se encontra no intervalo $[0, 1]$. A função *graythresh* usa o método de Otsu, que é uma técnica que determina um limiar ótimo considerando uma imagem I , que apresenta melhor funcionamento em imagens cujos histogramas são bimodais (Fig. 23). O objetivo do Método de Otsu aproximar o histograma de uma imagem por duas funções Gaussianas e escolher o limiar de forma a minimizar a variância intraclasses (OTSU, 1979).




Figura 23. Histograma bimodal.
Fonte: Acervo do autor.

No caso da ROI do grupo de microcalcificações, os histogramas obtidos tem uma distribuição unimodal. Ou seja, um histograma que apenas tem um pico, ou moda (Fig. 24). A função *graythresh* determina o limiar no valor médio da gaussiana, mas nesse limiar a imagem continua com muito ruído. Portanto, foi aplicado um limiar como 20% maior que o valor automático da função.




Figura 24. Histograma da ROI de m1.
Fonte: Acervo do autor.

O valor do limiar varia de um grupo de microcalcificação a outro, mas com a aplicação dessa limiarização é possível visualizar as regiões na imagem que correspondem a uma primeira aproximação das microcalcificações, ainda que sua forma e seu tamanho não

coincidam com as dimensões verdadeiras. Em seguida foi aplicada técnicas de crescimento regional usando operadores morfológicos, a partir da região na imagem com o pixel mais brilhante, que se denomina pixel semente. Dado que depois da limiarização pode acontecer que algumas das microcalcificações contenham pequenos orifícios equivalentes a pixels ou pequenos grupos de pixels originados pelo ruído. Esses defeitos são corrigidos com a aplicação desses operadores morfológicos como são o de abertura e fechamento, que estão baseados nas funções de erosão (*Erode*) e dilatação (*Dilate*) de pixels.

Essas funções trabalham a partir de elementos estruturantes (*Structural element, SE*) morfológicos que tem formas diversas. O elemento estrutural utilizado foi ($se = strel('disk',R)$), que cria um elemento de estruturação plana em forma de disco onde R especifica o raio, e deve ser um número inteiro não negativo. No algoritmos foi aplicado $R=3$ (Fig. 25).




Figura 25. Elemento estrutural em forma de disco de raio três.
Fonte: MATLAB, 2012.

Entre as funções dos operadores morfológicos utilizados no MATLAB estão:


Imdilate (I, SE): dilata a imagem.

Imerode (I, SE): erosão na imagem.

Imopen (I, SE): executa abertura morfológica na imagem I com o elemento estruturante SE. A operação de abertura morfológica é uma erosão seguida de uma dilatação, usando o mesmo elemento estruturante para ambas as operações.

Imclose (I, SE): executa o fechamento morfológico na imagem I com o elemento estruturante SE. A operação de fechamento morfológico é uma dilatação seguida de uma erosão, usando o mesmo elemento estruturante para ambas as operações.

A Figura 26 apresenta a variação de um grupo de microcalcificações aplicando a sequência de operadores morfológicos, Figura 26a um grupo depois de aplicar a limiarização e a Figura 26b o grupo logo após aplicar os operadores morfológicos.



(a)

(b)

Figura 26. Grupo de microcalcificações (a) Depois da limiarização e (b) Depois de aplicar os operadores morfológicos.

Fonte: Acervo do autor.

A continuação segue o diagrama de fluxo dos processos no processamento dos grupos de microcalcificações (Fig. 27).

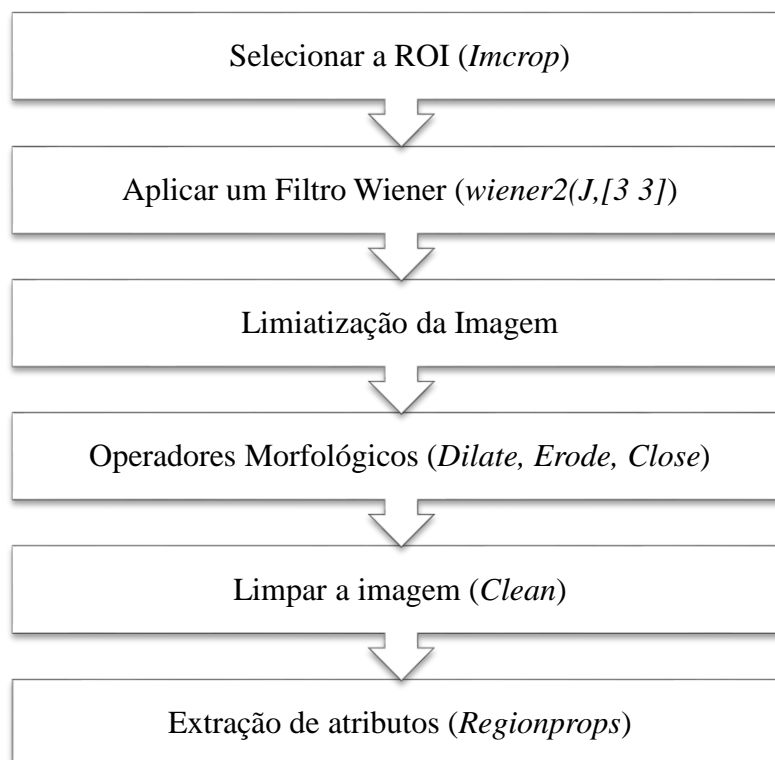


Figura 27. Diagrama do PDI sob os grupos de Microcalcificações.

Fonte: Acervo do autor.

Para a detecção do grupos de microcalcificações nas imagens adquiridas no mamógrafo instalado no LARAM algumas modificações foram realizadas. Inicialmente foi selecionada uma ROI em cada grupo e foi realizado o pré-processamento usando um filtro passa-baixo (Filtro *Wiener*), aplicado em todas as ROIs degradadas por ruídos aditivos. Em seguida, as ROIs foram segmentadas aplicando técnica de limiarização baseada no método de Niblack, onde o valor do limiar é baseado na média local e no desvio padrão dos pixels da região selecionada. Posteriormente foi aplicada uma série de operadores morfológicos como pós-processamento (dilatação, erosão e fechamento), para finalmente serem extraídas as propriedades das regiões visíveis e marcadas sob a imagem.

5.3.2 *Grades Metálicas*

Uma parte importante da avaliação da qualidade da imagem do *phantom* consiste na determinação da resolução espacial. Para isto, o *Phantom mama* tem as grades metálicas, estruturas que permitem avaliar esses parâmetros. Essas grades estão dispostas no *Phantom mama* como é mostrado no diagrama esquemático (Fig. 16), identificadas como G1, G2, G3 e G4, representando resoluções espaciais de 4, 6, 8 e 12 pl/mm, respectivamente.

Para analisar a imagem e desenvolver o algoritmo que defina até qual grade é visível na imagem, foram definidas ROI no interior das grades de 250 x 250 pixels (Fig. 28). Sob cada uma das ROIs foi feita uma análise de textura, fazendo uma abordagem estatística, consistindo na avaliação da textura da imagem definida por um conjunto de medidas locais extraídas do padrão ou medidas estatísticas comuns que incluem entropia, correlação, contraste e variância, entre outras.

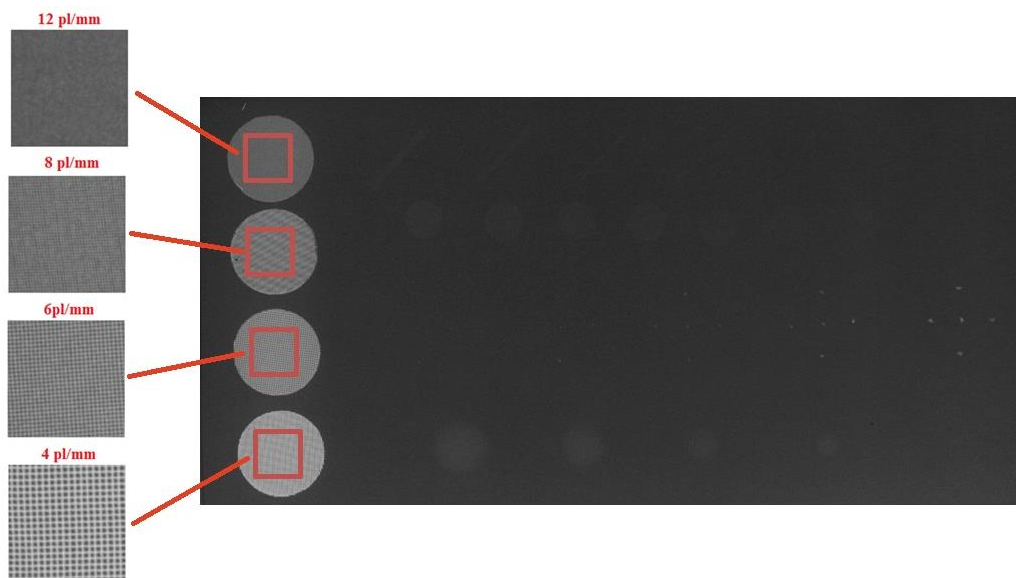


Figura 28. Seleção das ROIs de 250 x 250 pixels.

A análise de textura foi realizada a partir de abordagens estatísticas obtidas através de atributos extraídos da matriz de co-ocorrência de níveis de cinza (GLCM). Nos algoritmos desenvolvidos em MATLAB para criar a GLCM foi usada a função *graycomatrix*. A função *graycomatrix* cria a matriz de co-ocorrência calculando quantas vezes um pixel com o valor de intensidade (nível de cinza) i ocorre em uma relação espacial específica a um pixel com o valor j . A relação espacial foi definida entre o pixel de interesse e o pixel à sua direita imediata. Como o número de níveis de cinza da imagem determina o tamanho da GLCM, por padrão, a função *graycomatrix* usa a escala para reduzir o número de valores de intensidade de uma imagem para oito tons de cinza. No entanto, este parâmetro é modificável. A GLCM é utilizada para revelar certas propriedades sobre a distribuição espacial dos níveis de cinza na imagem de textura.

A partir disso, para cada um dos atributos do método estatístico utilizado foram estabelecidas regras de decisão probabilística, que definem se as grades são visualizadas ou não. O contraste e a energia são os principais atributos utilizados para definir a visualização das grades na imagem. O contraste é uma estimativa da média quadrada da variação dos níveis de cinza entre pares de elementos da imagem. A energia é um indicador de uniformidade ou suavidade das texturas. Na Tabela 6 estão definidos os critérios de avaliação.

Tabela 6. Critérios de Avaliação das Grades.

Estatística	Aceitação
Contraste	Valor maior que 0,1. Menor leva a uma imagem constante sem a variação devido aos pares de linhas presentes na ROI.
Correlação	Valores entre -1 e 1. O gráfico da correlação deve gerar uma imagem periódica que permite garantir uma relação entre os tons de cinza.
Energia	Valor menor que 0,5
Homogeneidade	Valor menor que 0,9

Adicionalmente, foram analisados os gráficos da correlação com respeito ao deslocamento horizontal na ROI com o objetivo de identificar a relação entre os pixels e seus vizinhos.

5.3.3 Massas e Fibras

Para a detecção dos massas e fibras foi utilizado o princípio da transformada de Hough para a detecção de círculos e linhas. Foram selecionadas as ROIs para cada um das massas e fibras presentes na imagem do phantom; realizou-se um pré-processamento aplicando um filtro de suavização e depois uma segmentação por detecção de contornos baseado nessa transformada.

A transformada de Hough é um método padrão para detecção de formas que são facilmente parametrizadas (linhas, círculos, elipses, etc.) em imagens digitais. O método consiste em que formas paramétricas em uma imagem sejam detectadas pela procura de pontos de acumulação no espaço de parâmetros. Se uma forma particular está presente na imagem, então o mapeamento de todos os seus pontos no espaço de parâmetros devem agrupar em torno dos valores de parâmetros que correspondem à forma.

Uma etapa necessária para a aplicação da transformada, foi a detecção das bordas na imagem depois de aplicado a segmentação. A segmentação foi feita aplicando uma limiarização usando a função *graythresh*. A detecção de bordas foi realizada usando a função *edge* que aplica por defeito o operador de Sobel. Em seguida ao aplicar a Transformada de Hough, se obtém os vetores de acumulação a partir dos quais são definidos os valores máximos encontrados, que equivalem as formas padrões, nesse caso círculos (Massas) e linhas (Fibras).

A Figura 29 apresenta o fluxo dos processos para a detecção e na Figura 30 a representação dessa sequência na detecção das massas.



Figura 29. Sequência para aplicar a transformada de Hough.




Figura 30. Sequência do processamento das massas usando a Transformada de Hough.

5.3.4 Discos

Para os discos presentes na imagem do *Phantom mama* foi proposto a medida da Razão Contraste-Ruído (CNR) como um parâmetro para o controle de qualidade da imagem digital. Para cálculo da CNR foram utilizadas as imagens adquiridas do simulador *Phantom mama*, no mamógrafo do LARAM/CDTN operando no modo CAE, todos os parâmetros foram registrados e as imagens foram salvas no modo *raw data*.

Para determinar esse valor foram selecionadas duas ROIs de 70 x 70 pixels, ROI₁, dentro das estruturas dos discos e ROI₂ no fundo da imagem (Fig. 31).




Figura 31. ROIs selecionadas para o cálculo da CNR.

Foram calculados o valor médio de pixel (VMP) e o desvio padrão (DP) em cada uma das ROIs. Definindo o valor da CNR para cada disco de acordo com a Equação 16 (YOUNG, 2006).

$$CNR = \frac{|VMP_f - VMP_{Di}|}{\sqrt{\frac{DP_f^2 + DP_{Di}^2}{2}}} \quad (\text{Equação 16})$$

onde VMP_f representa o Valor Médio do Pixel no fundo (paralelo ao disco) e VMP_{Di} representa o Valor Médio do Pixel em cada um dos i discos, e DP_f e DP_{Di} são os valores do desvio padrão para a ROI do fundo e dos discos, respectivamente.

5.4 Análise Estatística

A análise estatística dos resultados comparando a concordância da avaliação obtida pelos observadores e a avaliação semiautomática foi feita utilizando a ferramenta estatística de confiabilidade. O coeficiente kappa foi utilizado para avaliar a concordância entre a detecção

das estruturas feita pelos algoritmos e a avaliação visual, esse coeficiente avalia quão bem dois métodos classificam as estruturas nos grupos determinados.

Define-se em quantas categorias cada método deve classificar os objetos teste. Essas categorias são equivalentes ao número de estruturas presentes no *Phantom mama*. Para a avaliação dos grupos de microcalcificações e massas são cinco categorias respectivamente, ($\mu_1, \mu_2, \mu_3, \mu_4, \mu_5$) e (M1, M2, M3, M4, M5), para a avaliação das fibras são seis categorias (F1, F2, F3, F4, F5, F6) e para as grades são quatro categorias (G1, G2, G3, G4)

São preenchidas as células das linhas e colunas da tabela definida. As linhas designam como cada estrutura foi classificada pela avaliação visual. As colunas designam como o outro método classificou a mesma estrutura em cada imagem (Tab. 7). Os valores da diagonal da matriz representam que os dois métodos categorizaram identicamente o objeto teste. A avaliação visual foi definida estimando o valor médio dos observadores. Sendo que para valores de media não inteiros (3,25) foram passados a números inteiros cumprindo que se se encontram no intervalo (2,5 – 3,4) é equivalente a 3, (3,5 – 4,4) é equivalente a 4, e maior que 4,5 é equivalente a 5. Nesse caso 3,25 seria equivalente a 3, seria visível o terceiro grupo de microcalcificações.

Tabela 7. Tabela das frequências observadas em cada categoria.

		Computacional		
		CAT1	CAT 2	CAT 3
Observadores	CAT 1	0	0	0
	CAT 2	0	30	0
	CAT 3	0	0	2

Os valores apresentados nessas tabelas foram inseridos na folha de cálculo no site *GRANDHPAD Software* o qual faz a análise estatística dos valores esperados (P_E) e com os valores observados da tabela calcula o coeficiente kappa seguindo a equação 13.

Além do valor do coeficiente kappa o site proporciona o desvio padrão do kappa, o intervalo de confiança com 95%, o número de acordos observados, o número de acordos esperados por caso e o significado da força do acordo.

6. RESULTADOS E DISCUSSÃO

6.1 Imagens obtidas da base de dados da VISA

Os resultados obtidos após aplicar os algoritmos para a detecção dos grupos de microcalcificações se identificaram e realizaram contagem de centroides nas áreas brancas da imagem, classificando a imagem avaliada como aprovada, se o quarto grupo de microcalcificações fosse visualizada (Fig. 32).




Figura 32. Grupos de microcalcificações depois do processamento digital.

Foi feita uma análise comparativa entre a avaliação visual e automática para os grupos de microcalcificações. A Figura 33 apresenta a comparação das médias dos quatro avaliadores visuais (■) com seu respectivo desvio padrão que estão representados com barras de dispersão e o resultado da avaliação aplicando os algoritmos (*) para cada uma das imagens (Fig. 33).




Figura 33. Comparação da avaliação visual e automática dos grupos de microcalcificações.

Com os dados representados na figura 33, foi preenchida a tabela de frequências na folha de cálculo que classifica as imagens segundo o grupo de microcalcificações detectadas (Tab. 8).

Tabela 8. Frequências observadas dos grupos de microcalcificações

		Computacional				
		$\mu 1$	$\mu 2$	$\mu 3$	$\mu 4$	$\mu 5$
Observadores	$\mu 1$	0	0	0	0	0
	$\mu 2$	0	0	0	0	0
	$\mu 3$	0	0	2	6	0
	$\mu 4$	0	0	0	34	6
	$\mu 5$	0	0	0	0	2

O grau de concordância foi quantificado pelo coeficiente kappa. A avaliação foi feita comparando cada resposta dada pela média dos avaliadores visuais e a resposta depois de aplicar os algoritmos sob as imagens (Tab. 9).

Tabela 9. Estatística da concordância da avaliação visual e computacional dos grupos de microcalcificações.

Número de acordos observados	38 (76 % das observações)
Número de acordos esperados por acaso	32,6 (65,28% das observações)
Kappa	0,309
DP de kappa	0,146
Intervalo de confiança 95%	0,024 - 0,594
A força da concordância é considerada 'justo'.	

A concordância geral é estatisticamente diferente de zero e vale 0,309. Considerando que a concordância perfeita é a de 1,00, identificou-se uma concordância um pouco baixa considerada 'justo'. As microcalcificações são detalhes de alto contraste, porém de tamanhos muito pequenos e podem não ter sido vistas na avaliação da imagem visual devido o ruído gerado na aquisição da imagem.

Para a detecção das massas foram aplicados os algoritmos, usando a segmentação por limiarização. Na figura 34 pode ser visualizada até a quarta massa (M4). O processo de limiarização não mantém o contorno da imagem, então foi necessário aplicar o princípio de Hough para a detecção de círculos sob a imagem binarizada.




Figura 34. Massas depois do processamento digital.

O valor do desvio padrão das médias na avaliação visual das massas apresenta uma maior dispersão (Fig. 34). Isto é, a dificuldade na resolução do contraste da imagem pode levar a diferentes critérios na contagem das massas presentes na imagem, mais ainda na decisão da visibilidade da quinta massa.




Figura 35. Comparação da avaliação visual e semiautomática das massas nas imagens do *phantom mama*.

Apesar de ter maior dispersão nos dados de avaliação visual, depois de registrados os dados de frequência das massas observadas visual e computacionalmente, um grupo maior de imagens apresenta concordância no número de massas detectadas (47 imagens) (Tab. 10).

Tabela 10. Frequências observadas das massas.

		Computacional				
		M1	M2	M3	M4	M5
Observadores	M1	0	0	0	0	0
	M2	0	0	0	0	0
	M3	0	0	0	0	0
	M4	0	0	0	21	3
	M5	0	0	0	0	26

Comparando os resultados dados pelo valor médio dos avaliadores e ao aplicar os algoritmos nas imagens o kappa apresentou valor de 0,879 (Tab. 11). Isso representa uma concordância muito boa entre as respostas, como ‘Quase Perfeita’.

Tabela 11. Estatísticos da concordância da avaliação visual e computacional das massas.

Número de acordos observados	47 (94% das observações)
Número de acordos esperados por acaso	25,2 (50,32% das observações)
Kappa	0,879
DP de kappa	0,067
Intervalo de confiança 95%	De 0,748-1,000
A força do acordo é considerada como "Quase Perfeita"	

As fibras foram detectadas aplicando o princípio de detecção de linhas de Hough. A Figura 36 mostra o exemplo onde foi possível detectar até a quinta fibra (F5).




Figura 36. Fibras depois do processamento digital.

A avaliação das fibras utilizando os algoritmos apresentou inconvenientes para definir se a fibra era detectada ou não, isso porque a transformada em muitas ocasiões não delimita completamente a fibra, como por exemplo a quinta fibra (F5) na Figura 36.




Figura 37. Comparação da avaliação visual e automática das fibras.

Para avaliar as fibras foram definidas seis categorias, uma por cada fibra presente no *Phantom mama*. As avaliações foram distribuídas segundo as fibras fossem detectadas em cada um dos métodos (Tab. 12).

Tabela 12. Frequências observadas das fibras.

		Computacional					
		F1	F2	F3	F4	F5	F6
Observadores	F1	0	0	0	0	0	0
	F2	0	0	0	0	0	0
	F3	0	0	2	2	0	0
	F4	0	0	0	20	6	0
	F5	0	0	0	3	17	0
	F6	0	0	0	0	0	0

Para a detecção dos detalhes lineares de baixo contraste (Fibras) a partir dos dados das respostas das avaliações foi possível determinar o valor da concordância nesse caso (Tab. 13), com um valor kappa de 0,602, que obedece a uma força do acordo ‘Moderada’.

Tabela 13. Estatísticos da concordância da avaliação visual e computacional das fibras.

Número de acordos observados	39 (78% das observações))
Número de acordos esperados por acaso	22,4 (44,72% das observações)
Kappa	0,602
DP de kappa	0,106
Intervalo de confiança 95%	De 0,395-0,810
A força do acordo é considerada "Moderada".	

As imagens obtidas da base de dados da VISA foram adquiridas com diferentes sistemas de aquisição de imagens, portanto foi necessário realizar pequenas modificações nos algoritmos de uma imagem para outra. Para as três principais estruturas avaliadas a concordância entre os dois métodos de detecção foi aceitável, sendo ‘quase perfeita’ para as massas, ‘moderada’ para as fibras, e a maior discrepância foi com as microcalcificações, mais ainda assim se definiu como ‘justa’.

Em todas as estruturas avaliadas os algoritmos desenvolvidos detectam mais estruturas que os avaliadores visuais. Outros autores tem demonstrado a mesma tendência como Chakraborty (1995) depois de avaliar 27 imagens digitalizada do phantom acreditado pela ACR, a precisão de detecção aumenta usando a imagem depois de processamento computadorizado em um ganho de um fator de 9. Nas medidas realizadas dois anos depois (CHAKRABORTY, 1997) de 32 imagens digitais usando o programa de análise computacional CAMPI. Programa que também detectou mais estruturas que os observadores humanos.

Outras comparações entre uma avaliação visual e computadorizada de imagens do phantom acreditado da ACR Modelo RMI 156 analisado por Lee e seus colaboradores (2010) obteve precisão da avaliação computadorizada de 90%, 80%, e 98% para fibra, massa e microcalcificações, respectivamente. No entanto, a concordância entre os observadores e avaliação computadorizada tem associação significativa para microcalcificações, mas não para massas e fibras. A diferença da mostrada nesse trabalho onde as melhores concordâncias entre


avaliadores visuais e computacional está dada nas massas, e a menor nos grupos de microcalcificações.

As grades metálicas presentes no *Phantom mama* permitiram avaliar a resolução espacial da imagem. Para a avaliação dessas estruturas, foram utilizados atributos do método estatístico segundo as regras de decisão probabilísticas estabelecidas, que definem se as grades são visualizadas seguindo os critérios de avaliação mostrados na Tabela 2. Características dos atributos de textura. Na Tabela 14 estão apresentados os valores obtidos para cada um dos atributos utilizados aplicados nas ROIs de uma imagem padrão (Imagem Teste). Sendo o contraste, a energia, a homogeneidade e a correlação dos principais atributos utilizados para definir a visualização das grades na imagem.

Tabela 14. Resultados dos atributos de textura das ROIs de uma imagem padrão.

Região	Contraste	Correlação	Energia	Homogeneidade	Entropia
	> 0,1		< 0,5	< 0,9	
G1	2,1374	0,0083	0,0750	0,5752	6,6761
G2	1,1429	0,00034	0,1492	0,6638	5,7860
G3	0,9282	0,0036	0,1916	0,7008	4,8563
G4	0,4708	0,0397	0,3255	0,7646	3,9622

Os gráficos da correlação com respeito ao deslocamento horizontal na ROI podem confirmar uma relação entre os pixels e seus vizinhos, isso é um perfil horizontal da ROI demonstrando a periodicidade dos tons de cinzas, portanto, a definição da grade metálica (Fig. 38).






Figura 38. Correlação de Textura vs. Deslocamento Horizontal nas 4 ROIs.

Conseguiu-se demonstrar que para grades visíveis existe uma periodicidade na correlação dos pixels, a qual é evidenciada com a periodicidade da resposta.

Para comparar a avaliação visual e a avaliação computadorizada, foram selecionadas 10 diferentes imagens tomadas da base de dados da VISA-MG. As imagens em filme foram analisadas visualmente por quatro avaliadores treinados e, depois de serem digitalizadas, foram aplicados os algoritmos. A comparação da média obtida da avaliação visual, feita pelos avaliadores com seus respectivos desvios padrões, e a avaliação obtida pelos algoritmos é apresentada na Figura 39.




Figura 39. Comparação da avaliação visual e automática das grades nas imagens do *Phantom mama*.

O algoritmo para a análise automatizada identificou o número de grades 60% igual aos avaliadores visuais. Os resultados mostram que o método computacional introduzido é satisfatório para identificar imagens com nível semelhante de qualidade para o diagnóstico médico em um teste de controle de qualidade.

Da mesma forma que outros autores como Castellano e seus colaboradores (1998) tiveram como objetivo desenvolver um método objetivo da avaliação da qualidade de imagem, a fim de remover as variações inter-observador do processo de pontuação dos objetos teste com imagens digitalizadas, afirmaram nesse estudo que é necessário estabelecer restrições na utilização da técnica para a digitalização dos filmes, dado que os algoritmos não responderam bem em algumas ROIs enquanto que em outras, era parcialmente bem sucedida.

Nesse trabalho foi necessário focar num sistema de aquisição para a obtenção de imagens analisadas dado que muitas dificuldades foram encontradas em estabelecer algoritmos gerais satisfatórios para serem aplicados sobre todas as imagens coletadas, isso devido às imagens procederem de diversas fontes, ou seja, diferentes equipamentos de mamografia e diferentes sistemas de aquisição. Foi necessário estabelecer características particulares no processamento de cada uma dessas imagens. Em razão disso foram ajustados os algoritmos para a avaliação das imagens do *Phantom mama* obtidas pelo sistema CR, e assim eliminando a fase de digitalização, utilizando o scanner, como era o caso da avaliação com as imagens obtidas do programa PECQMamo.

6.2 Imagens do LARAM

Para determinar a área na imagem onde está o *Phantom mama* foi subtraída a região preta da imagem usando detecção de contorno aplicando o operador *Robert*, assim esse algoritmo retorna uma imagem na qual são definidas as ROIs a partir do ponto (X_{min}, Y_{min}) onde se dá início a imagem sob a qual se fazem as detecções das estruturas como se mostra na Figura 40. Os tamanhos das ROIs das estruturas avaliadas permanecem constantes e estão definidos na Tabela 15.

Tabela 15. Dimensões das ROIs para cada um dos objetos testes da imagem.

Objeto Teste	Dimensão da ROI (pixels)
Grades	170 x 170
Grupos de microcalcificações	350 x 350
Massas	270 x 270
Fibras	300x 350




Figura 40. Esquema das ROIs selecionadas na imagem do *Phantom mama*..

Os algoritmos desenvolvidos para a caracterização dos objetos teste do *Phantom mama*, foram feitos a partir de uma imagem padrão adquirida com os parâmetros técnicos de 28 kVp e 120 mAs na combinação Mo/Mo. A programação desses algoritmos ocorreu como foi explicado anteriormente utilizando a caixa de ferramentas para imagens do software MATLAB® Versão 7.14.

Os resultados da avaliação visual e automática de uma amostra de imagens (15 imagens) adquiridas no equipamento de mamografia instalado no LARAM com o sistema de aquisição de imagem CR estão demonstrados na Tabela 16, apresentando a média da avaliação visual feita por três observadores (VIS) e automática (AUT) pelos algoritmos.

Tabela 16. Resultados da avaliação visual e automática de uma amostra de imagens digitais.

kV	mAs	Massas		Grupo de Microcalcificações		Fibras		Grades	
		VIS.	AUT.	VIS.	AUT.	VIS.	AUT.	VIS.	AUT.
24	20	1	2	2	2	1	2	2	2
24	80	3	3	3	3	2	2	2	2
24	125	3	3	4	3	3	3	2	2
26	20	2	2	2	3	2	2	2	2
26	80	3	3	3	4	3	3	2	2
26	125	3	3	4	4	3	3	2	2
28	20	2	2	3	3	2	3	2	2
28	80	3	3	4	4	3	3	2	2
28	125	3	3	4	4	3	3	2	2
30	20	3	3	3	3	2	3	2	2
30	80	3	3	4	4	3	4	3	3
30	125	3	4	4	4	4	4	3	3
32	20	3	3	3	3	2	3	2	2
32	80	3	4	4	4	3	4	3	3
32	125	4	4	4	4	4	4	3	3

Para avaliar os grupos de microcalcificações, massas e fibras pela análise automatizada foram aplicados os algoritmos que definia o número de estruturas visualizadas.

As grades foram analisadas segundo o parâmetro de textura denominado *Energia*, que define a uniformidade da imagem. Se a energia é menor que 0,5 avalia-se como a uma grade definida. A Figura 41, mostra as ROIs das grades metálicas da Imagem com parâmetros de 28 kVp e usando o CAE (125 mAs), onde se pode distinguir até a segunda grade (G2), isto é confirmado pelos valores de Energia obtidos da GLCM das ROIs (Tab. 17).




Figura 41. ROIs das grades metálicas da imagem digital adquirida no sistema CR

Tabela 17. Valor do atributo 'Energia' para as ROIs das grades

ROI	Energia	Avaliação
G1	0,3791	Visível
G2	0,4940	Visível
G3	0,7041	Não Visível
G4	0,7100	Não Visível

Foi definido que essas ROIs representam uma imagem constante, dado que o valor da energia da terceira e quarta grade são maior que 0,5 e a resolução da imagem não permitiu distinguir as grades na imagem.

A Figura 42 apresenta a correlação na textura das ROIs das grades metálicas presentes na imagem do simulador. A periodicidade que se apresenta no perfil horizontal representa uma correlação espacial na imagem. Essa caracterização da regularidade na imagem permite estabelecer uma avaliação da resolução espacial nas imagens do *Phantom mama*.

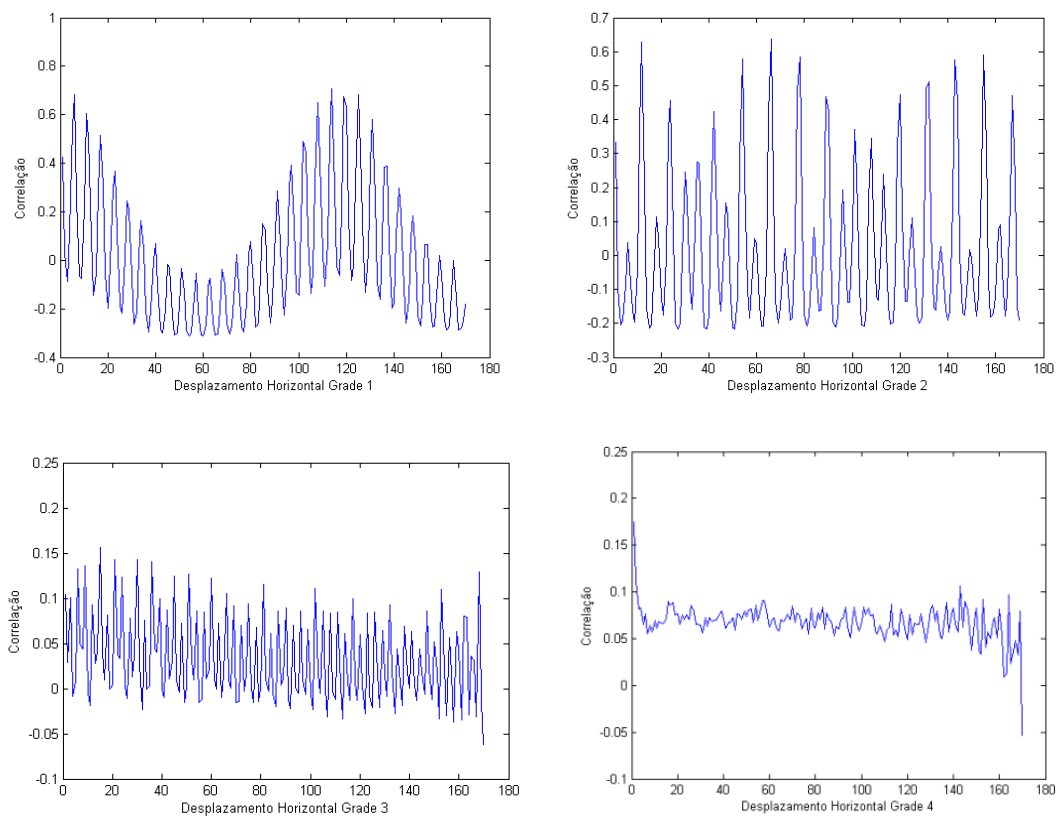


Figura 42. Correlação de Textura nas ROIs (grades) da imagem digital adquirida no sistema CR.

As tabelas de 18 – 21 apresentam as frequências observadas das estruturas detectadas nas imagens adquiridas no sistema CR, pela análise visual e aplicando os algoritmos.

Tabela 18. Frequências observadas das massas para imagens adquiridas no sistema CR

		Computacional				
		M1	M2	M3	M4	M5
Observadores	M1	0	1	0	0	0
	M2	0	2	0	0	0
	M3	0	0	9	2	0
	M4	0	0	0	1	0
	M5	0	0	0	0	0

Tabela 19. Frequências observadas dos grupos de microcalcificações para imagens adquiridas no sistema CR

		Computacional				
		m1	m2	m3	m4	m5
Observadores	m1	0	0	0	0	0
	m2	0	1	1	0	0
	m3	0	0	4	1	0
	m4	0	0	1	7	0
	m5	0	0	0	0	0

Tabela 20. Frequências observadas das fibras para imagens adquiridas no sistema CR

		Computacional					
		F1	F2	F3	F4	F5	F6
Observadores	F1	0	1	0	0	0	0
	F2	0	2	3	0	0	0
	F3	0	0	5	2	0	0
	F4	0	0	0	2	0	0
	F5	0	0	0	0	0	0
	F6	0	0	0	0	0	0

Tabela 21. Frequências observadas das grades para imagens adquiridas no sistema CR

		Computacional			
		G1	G2	G3	G4
Observadores	G1	0	0	0	0
	G2	0	11	0	0
	G3	0	0	4	0
	G4	0	0	0	0

Os Valores Kappa que permitem definir a concordância dos métodos de análises das imagens para uma amostra de imagens foram calculados com seu desvio padrão (DP- Kappa), o número de concordância para cada uma das estruturas avaliadas (Tab. 22).

Tabela 22. Valores Kappa que define a concordância entres os métodos de avaliação das estruturas.

Estrutura	Kappa	DP (Kappa)	Número de acordos (Porcentagem)	Avaliação
Massas	0.615	0.173	12 (80%)	Substancial
Grupo de Microcalcificações	0.651	0.175	12 (80%)	Substancial
Fibras	0.384	0.185	9 (60%)	Justo
Grades	1.000	0.000	15 (100%)	Quase Perfeita

Os valores do coeficiente kappa demonstram uma maior concordância nas imagens adquiridas pelo sistema de aquisição de imagem digital CR, isto é devido as imagens terem sido adquiridas em um mesmo sistema, diferente das imagens da base de dados da VISA-MG que são de diferentes centros, cada um com diferentes sistemas de aquisição da imagem do *phantom*.

Outros autores que compararam análise automática utilizando esse sistema de aquisição CR das imagens são Dougherty e Mayo, e também demonstraram que a análise computacional de simuladores de mama possibilitam um controle mais objetivo da qualidade de imagem nos equipamentos de mamografia.

Quando a imagem é adquirida pelos sistemas CR e DR, os parâmetros para a avaliação das estruturas podem apresentar modificações como a resolução espacial, que avalia a definição da imagem, dado que valores de frequência para a maioria dos sistemas mamográficos digitais estão entre 5 e 10 pl/mm. Estudos afirmam que a resolução espacial na detecção de pequenas estruturas não é o fator limitante. Esses estudos demonstram que é muito mais limitante um valor baixo da Razão Contraste–Ruído (*Contrast Noise Ratio* - CNR), que faz com que os detalhes com tamanhos superiores ao associado à frequência de Nyquist não sejam visíveis nas imagens (CHEVALIER, 2010).

Por último, para a avaliação de uma medida que permite definir a qualidade da imagem de uma mamografia com um sistema de aquisição de imagem digital se propõe calcular a CNR das imagens ‘*raw data*’ e definir os valores para cada sistema de aquisição de imagem. A Tabela 23 apresenta os valores de CNR medida em cada um dos discos da imagem do *phantom mama*, a imagem foi adquirida com parâmetros de exposição de 28 kVp e 125 mAs, salva em formato *DICOM* e em várias combinações Anodo/Filtro

Tabela 23. Valor de CNR dos discos

Discos	CNR (Mo/Mo)	CNR (Mo/Rh)	CNR (W/Rh)
D1	1.1331	0.8921	0.9833
D2	0.7435	0.6242	0.6039
D3	0.6464	0.5816	0.8853
D4	0.5259	0.4422	0.5075
D5	0.4796	0.3754	0.4522
D6	0.4176	0.3474	0.4298
D7	0.0871	0.3295	0.1537

Os Valores de CNR para cada disco foram plotados, a tendência no comportamento da CNR se mantém entre as combinações Anodo/Filtro (Fig. 43). Analisando visualmente essa imagem processada, é possível observar até o quarto disco na imagem, mas o objetivo dessa medição é estabelecer valores padrões para esse equipamento que permitam avaliar esse parâmetro de qualidade ao longo do tempo. Portanto, é necessário medições adicionais para avaliar esse índice de qualidade.

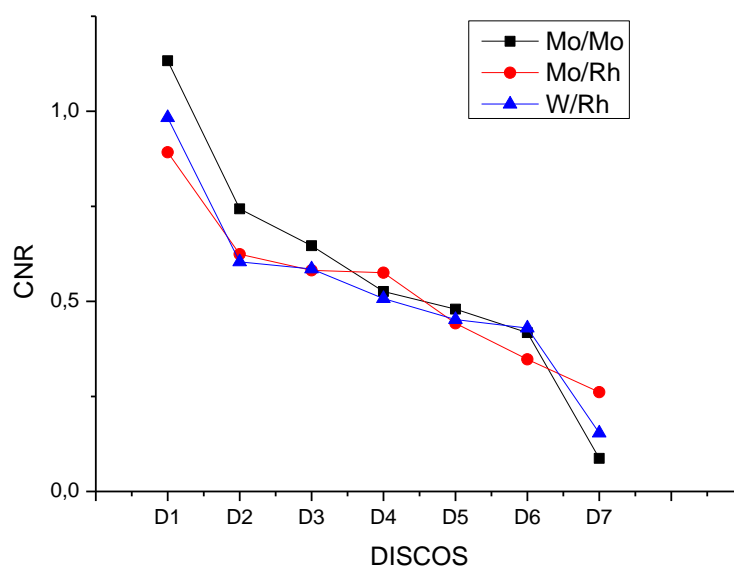


Figura 43. Valores de CNR nos discos presentes na imagem do Phantom mama.

7. CONCLUSÕES

Os algoritmos desenvolvidos para avaliar automaticamente os principais objetos teste das imagens do *Phantom mama*, simulador de mama reconhecido pelo Colégio Brasileiro de Radiologia, foram utilizados com sucesso em termos de localização correta dos detalhes dentro das imagens e a detecção das estruturas.

As concordâncias entre a avaliação automática e a avaliação visual foram aceitáveis para as massas, fibras e grupos de microcalcificações. Destacou-se a visibilidade das grades metálicas no sistema digital CR utilizando o método de análise de textura que apresentou a melhor concordância.

A utilização do coeficiente Kappa foi satisfatória para a avaliação da concordância entre dois métodos, e assim validar os algoritmos.

O grupo de imagens que apresentou melhor resposta foram as adquiridas no LARAM, acreditasse que as imagens adquiridas na VISA desde que sejam definidos critérios específicos para a aquisição das imagens como por exemplo geometria de posicionamento, entre outros.

A medição de índices de qualidade de imagem como a relação de contraste-ruído de alguns detalhes como os discos pode ser usada para avaliar a estabilidade a longo prazo de um sistema de mamografia digital. O teste de reprodutibilidade a longo prazo (CNR) com análise quantitativa de múltiplos índices de qualidade, a contagem de estruturas do phantom, demonstrou ser eficaz em prever falhas e pode ser utilizado para monitorar a estabilidade e a qualidade da imagem desses equipamentos.

O programa de avaliação automática permitirá diminuir a subjetividade, o tempo e o número de pessoas envolvidas na avaliação da qualidade da imagem, possibilitando a melhoria e expansão do Programa de Monitoramento da Qualidade dos Serviços de Mamografia.

REFERÊNCIAS

ACS - AMERICAN CANCER SOCIETY. *Breast Cancer Facts & Figures 2015-2016*. Atlanta: American Cancer Society, Inc. 2015.

BLOT L., *et al.* Automated quality assurance applied to mammographic imaging. *Journal on Applied Signal Processing*, n. 7, p. 736-745, 2002.

BRACATO, B.; *et al.* Do computer-aided detection (CAD) contribute to the performance of digital mammography in a self-referred population. *Breast Cancer Res Treat*, v. 111, p. 373–376, 2008.

BROOKS, K. W.; *et al.* Automated analysis of the American College of Radiology mammographic accreditation phantom images. *Medical Physics*, v. 24, No. 5, p. 709–722, 1997.

BRASIL. *Diretrizes de Proteção Radiológica em Radiodiagnóstico Médico e Odontológico*. Ministério da Saúde, Secretaria de Vigilância Sanitária Portaria 453 - 01 de junho de 1998

BRASIL. *Mamografia: da prática ao controle*. Ministério da Saúde. Instituto Nacional de Câncer. Rio de Janeiro. 2007.

BRASIL. Secretaria de Estado da Saúde de Minas Gerais. *Programa Estadual de Controle de Qualidade em Mamografia – PECQMamo Instrutivo do Monitoramento Mensal da Qualidade em Mamografia*. Versão 6.0, 2015.

BLIZNAKOVA K. S., PALLIKARAKIS N. E.. Quantitative Evaluation of a Mammographic Software Phantom, Member, *IEEE. Proceedings of the 9th International Conference on Information Technology and Applications in Biomedicine, ITAB*, 5-7 November, 2009.

BUSHONG, S.C. *Radiologic science for technologists: physics, biology and protection*. St. Louis: MOSBY, 2008.

CHAKRABORTY, D. P.; ECKERT, M. P. Quantitative versus subjective evaluation of mammography accreditation phantom images. *Med. Phys.*, n. 22, p.133-143, 1995.

CHAKRABORTY, D. P. Computer analysis of mammography phantom images (CAMPI): An application to the measurement of microcalcification image quality of directly acquired digital images. *Med. Phys.*, n. 24, p.1269-1277, 1997.

CHEVALIER, M.; TORRES, R. Mamografia digital. *Revista de Física Médica*, v. 11, n. 1, p. 11-26, 2010.

CASTELLANO, S. A. D.; CASTELLANO, S. I. A.; DANCE D. R. Objective assessment of phantom image quality in mammography: a feasibility study. *Br J Radiol*, n. 71, p.48-58, 1998.

CASTELLANO G., *et al* Review Texture analysis of medical images. *Clinical Radiology*, n. 59, p. 1061–1069, 2004.

COHEN J. A coefficient of agreement for nominal scales. *Educational and psychological measurement.*; n. 20, p. 37-46, 1960.

CEC - COMMISSION OF THE EUROPEAN COMMUNITIES. *European Protocol on Dosimetry in Mammography*. Report EUR 16263. European Commission. Office for Official Publications of the European Communities, Luxembourg, 1996.

DINIZ, P.; DESTRO FILHO, J. E. Processamento de imagens e relação de atividade elétrica com densidade de células neurais. *Horizonte Científico*, v. 4, n. 2, 2010.

DOUGHERTY G. Computerized evaluation of mammographic image quality using phantom images. *Comput. Med. Imaging Graphics*, n. 22, p. 365-373, 1998.

FUJITA, H.; *et al*. Computer aided diagnosis: The emerging of three CAD system induced by Japanese health care needs. *Computer Methods and Programs in Biomedicine*, v. 92, p. 238–248, 2008.

GENNARO, G.; *et al*. Automated analysis of phantom images for the evaluation of long-term reproducibility in digital mammography. *Physics in Medicine and Biology*, v. 52, p. 1387–1407, 2007.

GONZALEZ, R. WOODS C. E. *Processamento de Imagens Digitais*. Tradução do original Digital Image Processing. Edgard Blucher, São Paulo, 2000.

GOMES, O. F. M. Automação de Análise de Mutagênese em Tradescantia. PROCEEDINGS OF V REGIONAL CONGRESS ON RADIATION PROTECTION AND SAFETY, Recife, Brasil, 2001.

GRANDHPAD Software. Quantify agreement with kappa Disponível em: <<http://graphpad.com/quickcalcs/kappa1/>> Acesso em: 25 de Abril, 2016.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, p. 610-621, 3-6 November, 1973.

IAEA. INTERNATIONAL ATOMIC ENERGY AGENCY. *Quality Assurance Programme for Digital Mammography*. IAEA Human Health Series 17. Vienna: IAEA, 2011.

IAEA. INTERNATIONAL ATOMIC ENERGY AGENCY. *Diagnostic radiology physics: a handbook for teachers and students*. Chapter 9: Mammography. Vienna : 2014.

IAEA. INTERNATIONAL ATOMIC ENERGY AGENCY. *Exposure indicators and patient dose estimation in CR and DR*. Radiation Protection in Digital Radiology. Disponível em <https://rpop.iaea.org/RPOP/RPoP/Content/AdditionalResources/Training/1_TrainingMaterial/DigitalRadiology.htm> . Acesso em: 15 dez. 2015.

INCA. INSTITUTO NACIONAL DO CÂNCER. *Estimativa 2016: Incidência de câncer no Brasil*. Disponível em < <http://www.inca.gov.br/wcm/dncc/2015/estimativa-2016.asp>>. Acesso em: 15 dez. 2015.

INCA. INSTITUTO NACIONAL DO CÂNCER. *SISMAMA. Informação para o avanço das ações de controle do câncer de mama no Brasil*. Rio de Janeiro, 2010.

INCA. INSTITUTO NACIONAL DO CÂNCER. *Controle do câncer de mama. Documento de consenso*. Ministério da Saúde. Instituto Nacional de Câncer/ Rio de Janeiro, 2004.

JAKUBIAK, RR. Qualidade da Imagem, Limiar de contraste e Dose Glandular Média em Mamografia Digital CR. 2013. Tese (Doutorado em Ciências). Universidade Tecnológica Federal do Paraná, 2013.

KOOMEN, M.; *et al.* Future Directions in Breast Imaging. *Journal of Clinical Oncology*, n. 23, p. 1674-1677, 2005.

KOREN, N. *Understanding image sharpness part 2: Resolution and MTF curves in scanners and sharpening*. Disponível em < <http://www.normankoren.com/Tutorials/MTF2.html>>. Acesso em 05 de jan. 2016.

LANDIS J, KOCH G: The measurement of observer agreement for categorical data. *Biometric*. n. 33, p.159-174. 1977.

LEE Y.; TSAI, D. Y.; SHINOHARA, N. Computerized quantitative evaluation of mammographic accreditation phantom images. *Med. Phys.*, n. 37, p. 6323-6331, 2010.

MAYO, P.; *et al.* Automatic evaluation of the image quality of a mammographic phantom. *Computer Methods Programs Biomed*, v. 73, p. 115 - 128, 2004.

MAYO, P.; *et al.* Quality assurance applied to mammographic equipments using phantoms and software for its evaluation. *Nucl. Instrum. Methods*, n. 619, p. 372-374, 2010.

MATHWORKS. MATLAB and Simulink. 2012.

MINAS GERAIS. SECRETARIA DE ESTADO DE SAÚDE. *Resolução SES nº. 1356, de 20 de dezembro de 2007*. Disponível em: <http://www.saude.mg.gov.br/atos_normativos/resolucoes/2007/resolucao_1356.pdf>. Acesso em: 8 de jan de 2016.

MINAS GERAIS (Estado). Secretaria de Estado de Saúde de Minas Gerais. *Programa Estadual de Controle de Qualidade em Mamografia – PECQMamo: Instrutivo do Monitoramento Mensal da Qualidade em Mamografia*. v. 4.0. 2013.

OTSU, N. A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, v. 9, n. 1, p. 62-66, 1979.

PAIXÃO, L. *Metodologia para geração de modelos de mama com distribuição espacial de tecido glandular*. 2015. Tese (Doutorado em Ciências e Tecnologia das Radiações, Minerais e Materiais) Centro de Desenvolvimento de Tecnologia Nuclear, 2015.

PEIXOTO, J. E.; KOCH, H. A.; DOMINGUES, C.. Manual de instruções para as medidas de controle de qualidade dos parâmetros técnicos da mamografia. *Radiol. Bras.* v. 33, n.4, p. 233-239, 2000.

PEREIRA, L. S., *et al.* Utilização de diferentes simuladores na avaliação da qualidade da imagem em mamografia digital. In: IX Latin American IRPA Regional Congress on Radiation Protection and Safety - IRPA 2013. Rio de Janeiro. Anais de Congressos. 2013.

PERRY, N.; *et al.* European guidelines for quality assurance in breast cancer screening and diagnosis. *Annals of Oncology*, v. 19, p. 614–622, 2008.

PIRES, G. M.; *et al.* Arquitetura Para um Sistema de Diagnóstico Auxiliado por Computador. In: X Congresso Brasileiro de Informática em Saúde, Florianópolis: SBIS, v. 1, p. 890-895, 2006.

SEIXAS, F. L; *et al.* Avaliação dos métodos para a segmentação automática dos tecidos do encéfalo em ressonância magnética. Simpósio de Pesquisa Operacional e Logística da Marinha, SPOLM, Rio de Janeiro, Brasil, 2008.

TOMAL, A. Mammography Phantoms. In: Larry DeWerd; Michael Kissick. (Org.). Phantoms of Medical and Health Physics: Devices for Research and Development. New York: Springer New York, 2014, p. 143-157. 2014.

THOMÉ, A. *Processamento de Imagens. Tratamento da Imagem – Filtros*. Disponível em <http://equipe.nce.ufrj.br/thome/p_grad/nn_img/transp/c4_filtros.pdf>. Acesso em: 15 Mar. 2016.

YOUNG, K. C.; *et al.* Comparison of software and human observers in reading images of the CDMAM test object to assess digital mammography systems. In Proceedings of SPIE, Medical Imaging, v. 6142, p. 1-13, 2006.

ANEXO

Comandos destacados dos algoritmos desenvolvidos

Função	Comando Matlab	Descrição
Leitura da Imagem	$I = \text{imread}(\dots)$	Lê uma imagem em tons de cinza ou de cor do arquivo especificado pelo nome do arquivo string.
ROIs	$\text{Imcrop}(x, y, dx, dy)$	Corta a imagem, criando as ROIs na localização desejada.
Filtro Wiener	$\text{wiener2}(I, [m\ n])$	Filtragem adaptativa para remoção de ruído. Filtra a imagem I usando vizinhança de tamanho m x n para estimar a local média e desvio padrão da imagem.
Threshold ou Limiar	$\text{Level} = \text{Graythresh}(I)$	Limiar global imagem usando o método de Otsu. Calcula um limiar global (nível) que pode ser utilizado para converter uma imagem intensa de uma imagem binária com im2bw . Nível (<i>level</i>) é um valor de intensidade normalizada que se encontra no intervalo [0, 1]
Binarização	$\text{BW} = \text{im2bw}(I, \text{level})$	Converte a imagem em tons de cinza (I) a uma imagem binária, baseado no limiar (<i>level</i>)
Elemento Estrutural	$\text{SE} = \text{strel}(\text{'disk'}, R)$	Cria um elemento estruturante, SE, do tipo especificado pela forma. Nesse caso, em forma de disco.
Dilatar	$\text{IM} = \text{imdilate}(I, \text{SE})$	Dilata os tons de cinza, ou a imagem binária (I) a partir do elemento estrutural (SE)
Corroer	$\text{IM} = \text{imerose}(I, \text{SE})$	Corrói os tons de cinza, binário da imagem (I), retornando a imagem desgastada (IM), a partir do SE.
Abertura	$\text{IM} = \text{imopen}(I, \text{SE})$	Realiza abertura morfológica na imagem em tons de cinza ou binário (I) com o elemento estruturante SE. A operação morfológica aberta é uma erosão seguida por uma dilatação, usando o mesmo elemento estruturante para ambas as operações
Fechamento	$\text{IM} = \text{imclose}(I, \text{SE})$	Realiza fechamento morfológico na escala de cinza ou imagem binária (I), retornando a imagem fechada, (IM). A operação de fechamento morfológica é uma dilatação seguida de uma erosão, usando o mesmo elemento estruturante para ambas as operações.
Preenchimento	$\text{IM} = \text{imfill}(I)$	
Propriedades de objetos	$\text{STATS} = \text{regionprops}(I, \text{properties})$	Mede um conjunto de propriedades de cada componente ligado (objeto) na imagem binária (I). As propriedades podem ser Área, Centroides, número de pixels, entre outras.
Transformada de Hough	$[H, \text{theta}, \text{rho}] = \text{Hough}(I)$	Calcula a transformada de Hough padrão da imagem binária (I).
Matriz de Co-ocorrência de Tons de Cinza (GLCM)	$\text{glcms} = \text{graycomatrix}(I)$	Cria o GLCM de uma Imagem I, calculando quantas vezes um pixel com valor de nível de cinza (intensidade em tons de cinza) i ocorre horizontalmente adjacente a um pixel com o valor j.

```

i=imread('D:\cmvb\Pictures\IMAGES\
image test.tif');
i = im2double(i);
a = .299*i(:, :, 1) + .587*i(:, :, 2)
+ .114*i(:, :, 3);

```

GRUPO DE MICROCALCIFICAÇÕES

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

```

m1=imcrop(a, [6130,1550,750,770]);
m2=imcrop(a, [4900,1550,750,770]);
m3=imcrop(a, [3730,1550,750,770]);
m4=imcrop(a, [2700,1550,750,770]);
m5=imcrop(a, [1550,1550,750,770]);

```

```

figure (1);
subplot(1,5,1), imshow(m1);
subplot(1,5,2), imshow(m2);
subplot(1,5,3), imshow(m3);
subplot(1,5,4), imshow(m4);
subplot(1,5,5), imshow(m5);

```

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% GRUPO 1%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

```

K = wiener2(m1, [3 3]);
T = graythresh(K);
T= (1.20)*T;
bw=im2bw(K,T);
se = strel('disk',3);
bw2 = imdilate(bw,se);
se1 = strel('disk',3);
bw3 = imerode(bw2,se1);
bw4 = imopen(bw3,se);
bw5 = imclose(bw4,se);
B=bwmorph(bw5, 'clean');

```

```

figure (3); subplot(1,2,1),
imshow(m1); subplot(1,2,2),
imshow(K);

```

```

figure (4); subplot(1,2,1),
imhist(m1); subplot(1,2,2),
imhist(K);

```

```

L = bwlabel(B);
s = regionprops(L, 'centroid');
s1 = regionprops(L, 'ConvexArea');
centroids = cat(1, s.Centroid);
figure(2), subplot(1,5,1),
imshow(B)
whos s1
hold on
plot(centroids(:,1),
centroids(:,2), 'r*')
hold off

```

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% GRUPO 2%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

```

K = wiener2(m2, [3 3]);
T = graythresh(K);
T= (1.20)*T;
bw=im2bw(K,T);

```

```

se = strel('disk',3);
bw2 = imdilate(bw,se);
se1 = strel('disk',3);
bw3 = imerode(bw2,se1);
bw4 = imopen(bw3,se);
bw5 = imclose(bw4,se);

```

```

B=bwmorph(bw5, 'clean');

```

```

L = bwlabel(B);
s = regionprops(L, 'centroid');
s1 = regionprops(L, 'ConvexArea');
centroids = cat(1, s.Centroid);
figure(2), subplot(1,5,2),
imshow(B)
whos s1
hold on
plot(centroids(:,1),
centroids(:,2), 'r*')
hold off

```

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% GRUPO 3%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

```

K = wiener2(m3, [3 3]);
T = graythresh(K);
T= (1.20)*T;
bw=im2bw(K,T);

```

```

se = strel('disk',3);
bw2 = imdilate(bw,se);

```

```

se1 = strel('disk',3);
bw3 = imerode(bw2,se1);

```

```

bw4 = imopen(bw3,se);
bw5 = imclose(bw4,se);

```

```

B=bwmorph(bw5, 'clean');

```

```

L = bwlabel(B);
s = regionprops(L, 'centroid');
s1 = regionprops(L, 'ConvexArea');
centroids = cat(1, s.Centroid);
figure(2), subplot(1,5,3),
imshow(B)
whos s1
hold on
plot(centroids(:,1),
centroids(:,2), 'r*')
hold off

```

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% GRUPO 4%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

```

```

K = wiener2(m4, [3 3]);
T = graythresh(K);
T= (1.20)*T;

```

```

bw=im2bw(K,T);

se = strel('disk',3);
bw2 = imdilate(bw,se);

se1 = strel('disk',3);
bw3 = imerode(bw2,se1);

bw4 = imopen(bw3,se);
bw5 = imclose(bw4,se);

B=bwmorph(bw5,'clean');

L = bwlabel(B);
s = regionprops(L, 'centroid');
s1 = regionprops(L, 'ConvexArea');
centroids = cat(1, s.Centroid);
figure(2), subplot(1,5,4),
imshow(B)
whos s1
hold on
plot(centroids(:,1),
centroids(:,2), 'r*')
hold off

%%%%%%%%%%%%% GRUPO 5%%%%%%%%%%%%%

K = wiener2(m5,[3 3]);
T = graythresh(K);
T= (1.20)*T;
bw=im2bw(K,T);

se = strel('disk',3);
bw2 = imdilate(bw,se);

se1 = strel('disk',3);
bw3 = imerode(bw2,se1);

bw4 = imopen(bw3,se);
bw5 = imclose(bw4,se);

B=bwmorph(bw5,'clean');

L = bwlabel(B);
s = regionprops(L, 'centroid');
s1 = regionprops(L, 'ConvexArea');
centroids = cat(1, s.Centroid);
figure(2), subplot(1,5,5),
imshow(B)
whos s1
hold on
plot(centroids(:,1),
centroids(:,2), 'r*')
hold off

```

MASSAS

```

%%%%%%%%%eleção de ROIs%%%%%%%%%
%%%%%%%%%MASSAS%%%%%%%%%
M1=imcrop(a,[1900,2710,700,540]);
M2=imcrop(a,[2950,2710,700,540]);
M3=imcrop(a,[3950,2710,700,540]);
M4=imcrop(a,[5000,2710,700,540]);
M5=imcrop(a,[5800,2710,700,540]);

%%%%%%%%%MASSA 1 %%%%%%%%%%
%Aplicacion Filtro
K = medfilt2(M1,[1 1]);
%Transformação em escala de cinza
threshold = graythresh(K);
threshold = (1.05)*threshold;
bw1 = im2bw(K,threshold);
% remover todo objeto que contém
menos de 30 pixels
bw1 = bwareaopen(bw1,2000);
% preencher as lacunas
se = strel('disk',3);
bw1 = imclose(bw1,se);
% preencher todos os buracos, de
modo que regionprops pode ser
utilizado para estimar a área
delimitada por cada borda
im = imfill(bw1,'holes');
figure
(1);subplot(1,5,1);imshow(im);titl
e('M1')

ims = conv2(double(im),
ones(7,7),'same');
imbw = ims>6;

props =
regionprops(imbw,'Area','PixelIdxL
ist','MajorAxisLength','MinorAxisL
ength');
[~,indexOfMax] =
max([props.Area]);
approximateRadius =
props(indexOfMax).MajorAxisLength/
2;

largestBlobIndexes =
props(indexOfMax).PixelIdxList;
bw = false(size(im));
bw(largestBlobIndexes) = 1;
bw = imfill(bw,'holes');

radiuses = round (
(approximateRadius-
5):0.5:(approximateRadius+5) );
h = circle_hough(edge(bw),
radiuses,'same');
[~,maxIndex] = max(h(:));
[i,j,k] = ind2sub(size(h),
maxIndex);

```

```

radius = radiuses(k);
center.x = j;
center.y = i;

figure(2);subplot(1,5,1);imshow(M1
);imellipse(gca,[center.x-radius
center.y-radius 2*radius
2*radius]);
title('M1');

%%%%%%%%%%MASSA 2 %%%%%%%%%%%

%Aplicacion Filtro
K = medfilt2(M2,[1 1]);
%Transformação em escala de cinza
threshold = graythresh(K);
threshold = (1.05)*threshold;
bw1 = im2bw(K,threshold);
% remover todo objeto que contém
menos de 30 pixels
bw1 = bwareaopen(bw1,2000);
% preencher as lacunas
se = strel('disk',3);
bw1 = imclose(bw1,se);
% preencher todos os furos, de
modo que regionprops pode ser
utilizado para estimar a área
delimitada por cada borda
im = imfill(bw1,'holes');
figure
(1);subplot(1,5,2);imshow(im);titl
e('M2')

ims = conv2(double(im),
ones(7,7),'same');
imbw = ims>6;

props =
regionprops(imbw,'Area','PixelIdxL
ist','MajorAxisLength','MinorAxisL
ength');
[~,indexOfMax] =
max([props.Area]);
approximateRadius =
props(indexOfMax).MajorAxisLength/
2;

largestBlobIndexes =
props(indexOfMax).PixelIdxList;
bw = false(size(im));
bw(largestBlobIndexes) = 1;
bw = imfill(bw,'holes');

radiuses = round (
(approximateRadius-
5):0.5:(approximateRadius+5) );
h = circle_hough(edge(bw),
radiuses,'same');
[~,maxIndex] = max(h(:));

```

```

[i,j,k] = ind2sub(size(h),
maxIndex);
radius = radiuses(k);
center.x = j;
center.y = i;

figure(2);subplot(1,5,2);imshow(M2
);imellipse(gca,[center.x-radius
center.y-radius 2*radius
2*radius]);
title('M2');

%%%%%%%%%%MASSA 3 %%%%%%%%%%%

%Aplicacion Filtro
K = medfilt2(M3,[1 1]);
%Transformação em escala de cinza
threshold = graythresh(K);
threshold = (1.07)*threshold;
bw1 = im2bw(K,threshold);
% remover todo objeto que contém
menos de 30 pixels
bw1 = bwareaopen(bw1,2000);
% preencher as lacunas
se = strel('disk',3);
bw1 = imclose(bw1,se);
% preencher todos os buracos, de
modo que regionprops pode ser
utilizado para estimar a área
delimitada por cada borda im =
imfill(bw1,'holes');
figure
(1);subplot(1,5,3);imshow(im);titl
e('M3')

ims = conv2(double(im),
ones(7,7),'same');
imbw = ims>6;

props =
regionprops(imbw,'Area','PixelIdxL
ist','MajorAxisLength','MinorAxisL
ength');
[~,indexOfMax] =
max([props.Area]);
approximateRadius =
props(indexOfMax).MajorAxisLength/
2;

largestBlobIndexes =
props(indexOfMax).PixelIdxList;
bw = false(size(im));
bw(largestBlobIndexes) = 1;
bw = imfill(bw,'holes');

radiuses = round (
(approximateRadius-
5):0.5:(approximateRadius+5) );
h = circle_hough(edge(bw),
radiuses,'same');

```

```

    [~,maxIndex] = max(h(:));
    [i,j,k] = ind2sub(size(h),
maxIndex);
    radius = radiuses(k);
    center.x = j;
    center.y = i;

figure(2);subplot(1,5,3);imshow(M3
);imellipse(gca,[center.x-radius
center.y-radius 2*radius
2*radius]);
    title('M3');

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%Aplicacion Filtro
K = medfilt2(M4,[1 1]);
%Transformação em escala de cinza
threshold = graythresh(K);
threshold = (1.08)*threshold;
bw1 = im2bw(K,threshold);
% remover todo objeto que contém
menos de 30 pixels
bw1 = bwareaopen(bw1,2000);
% preencher as lacunas
se = strel('disk',3);
bw1 = imclose(bw1,se);
% preencher todos os buracos, de
modo que regionprops pode ser
utilizado para estimar a área
delimitada por cada borda
im = imfill(bw1,'holes');
figure
(1);subplot(1,5,4);imshow(im);titl
e('M4');

    ims = conv2(double(im),
ones(7,7),'same');
    imbw = ims>6;
    %
    props =
regionprops(imbw,'Area','PixelIdxL
ist','MajorAxisLength','MinorAxisL
ength');
    [~,indexOfMax] =
max([props.Area]);
    approximateRadius =
props(indexOfMax).MajorAxisLength/
2;

    largestBlobIndexes =
props(indexOfMax).PixelIdxList;
    bw = false(size(im));
    bw(largestBlobIndexes) = 1;
    bw = imfill(bw,'holes');

    radiuses = round (
(approximateRadius-
5):0.5:(approximateRadius+5) );

```

```

    h = circle_hough(edge(bw),
radiuses,'same');
    [~,maxIndex] = max(h(:));
    [i,j,k] = ind2sub(size(h),
maxIndex);
    radius = radiuses(k);
    center.x = j;
    center.y = i;

figure(2);subplot(1,5,4);imshow(M4
);imellipse(gca,[center.x-radius
center.y-radius 2*radius
2*radius]);
    title('M4');

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%Aplicacion Filtro
K = medfilt2(M5,[1 1]);
%Transformação em escala de cinza
threshold = graythresh(K);
threshold = (1.08)*threshold;
bw1 = im2bw(K,threshold);
% remover todo objeto que contém
menos de 30 pixels bw1 =
bwareaopen(bw1,2000);
% preencher as lacunas
se = strel('disk',3);
bw1 = imclose(bw1,se);
% preencher todos os buracos, de
modo que regionprops pode ser
utilizado para estimar a área
delimitada por cada borda
im = imfill(bw1,'holes');
figure
(1);subplot(1,5,5);imshow(im);
title('M5');

    ims = conv2(double(im),
ones(7,7),'same');
    imbw = ims>6;

    props =
regionprops(imbw,'Area','PixelIdxL
ist','MajorAxisLength','MinorAxisL
ength');
    [~,indexOfMax] =
max([props.Area]);
    approximateRadius =
props(indexOfMax).MajorAxisLength/
2;

    largestBlobIndexes =
props(indexOfMax).PixelIdxList;
    bw = false(size(im));
    bw(largestBlobIndexes) = 1;
    bw = imfill(bw,'holes');

```

```

    radiuses = round (
    (approximateRadius-
    5):0.5:(approximateRadius+5) );
    h = circle_hough(edge(bw),
    radiuses, 'same');
    [~,maxIndex] = max(h(:));
    [i,j,k] = ind2sub(size(h),
    maxIndex);
    radius = radiuses(k);
    center.x = j;
    center.y = i;

figure(2);subplot(1,5,5);imshow(M5
);imellipse(gca,[center.x-radius
center.y-radius 2*radius
2*radius]);
    title('M5');

```

FIBRAS

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
F1=imcrop(a,[1450,240,620,510]);
F2=imcrop(a,[2300,240,620,510]);
F3=imcrop(a,[3180,240,620,510]);
F4=imcrop(a,[4000,240,620,510]);
F5=imcrop(a,[4780,240,620,510]);
F6=imcrop(a,[5500,240,620,510]);

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
Fibra1%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

T = graythresh(F1);
T= (1.08)*T;
bw=im2bw(F1,T);
se = strel('disk',1);
bw2 = imerode(bw,se);
B= bwareaopen(bw2,10);
sel = strel('line',100,45);
bw = imdilate(B,sel);
[H,T,R]=hough (bw);
P=houghpeaks(H,1);
lines=houghlines(bw,T,R,P);

subplot(1,6,1)
imshow(F1);title('F1'); hold on
max_len=0;

for k=1:length(lines)
xy=[lines(k).point1;
lines(k).point2];
plot(xy(:,1),xy(:,2),'LineWidth',2
,'Color','red');
plot(xy(1,1),xy(1,2),'x','LineWidt
h',2,'Color','red');
plot(xy(2,1),xy(2,2),'x','LineWidt
h',2,'Color','red');
len=norm(lines(k).point1 -
lines(k).point2);
end

```

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
Fibra2%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

T = graythresh(F2);
T= (1.10)*T;
bw=im2bw(F2,T);
se = strel('disk',1);
bw2 = imerode(bw,se);
B= bwareaopen(bw2,10);
sel = strel('line',100,45);
bw = imdilate(B,sel);
[H,T,R]=hough (bw);
P=houghpeaks(H,1);
lines=houghlines(bw,T,R,P);

subplot(1,6,2)
imshow(F2);title('F2'); hold on
max_len=0;

for k=1:length(lines)
xy=[lines(k).point1;
lines(k).point2];
plot(xy(:,1),xy(:,2),'LineWidth',2
,'Color','red');
plot(xy(1,1),xy(1,2),'x','LineWidt
h',2,'Color','red');
plot(xy(2,1),xy(2,2),'x','LineWidt
h',2,'Color','red');
len=norm(lines(k).point1 -
lines(k).point2);
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
Fibra3%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

T = graythresh(F3);
T= (1.10)*T;
bw=im2bw(F3,T);
se = strel('disk',1);
bw2 = imerode(bw,se);

B= bwareaopen(bw2,10);

sel = strel('line',100,45);
bw = imdilate(B,sel);

[H,T,R]=hough (bw);
P=houghpeaks(H,1);

lines=houghlines(bw,T,R,P);
subplot(1,6,3)
imshow(F3);title('F3'); hold on
max_len=0;

for k=1:length(lines)
xy=[lines(k).point1;
lines(k).point2];
plot(xy(:,1),xy(:,2),'LineWidth',2
,'Color','red');
plot(xy(1,1),xy(1,2),'x','LineWidt
h',2,'Color','red');
plot(xy(2,1),xy(2,2),'x','LineWidt
h',2,'Color','red');

```

```

len=norm(lines(k).point1 -
lines(k).point2);
end

%%%%%%%%%Fibra 4%%%%%%%%%

T = graythresh(F4);
T= (1.10)*T;
bw=im2bw(F4,T);
se = strel('disk',1);
bw2 = imerode(bw,se);

B= bwareaopen(bw2,10);

se1 = strel('line',100,45)
bw = imdilate(B,se1);

[H,T,R]=hough (bw);
P=houghpeaks(H,1);

lines=houghlines(bw,T,R,P);
subplot(1,6,4)
imshow(F4);title('F4'); hold on
max_len=0;

for k=1:length(lines)
xy=[lines(k).point1;
lines(k).point2];
plot(xy(:,1),xy(:,2),'LineWidth',2
,'Color','red');
plot(xy(1,1),xy(1,2),'x','LineWidt
h',2,'Color','red');
plot(xy(2,1),xy(2,2),'x','LineWidt
h',2,'Color','red');
len=norm(lines(k).point1 -
lines(k).point2);
end

%%%%%%%%%Fibra5%%%%%%%%%

T = graythresh(F5);
T= (1.10)*T;
bw=im2bw(F5,T);
se = strel('disk',1);
bw2 = imerode(bw,se);

B= bwareaopen(bw2,10);

se1 = strel('line',100,45)
bw = imdilate(B,se1);

[H,T,R]=hough (bw);
P=houghpeaks(H,1);

lines=houghlines(bw,T,R,P);
subplot(1,6,5)
imshow(F5);title('F5'); hold on
max_len=0;

for k=1:length(lines)

```

```

xy=[lines(k).point1;
lines(k).point2];
plot(xy(:,1),xy(:,2),'LineWidth',2
,'Color','red');
plot(xy(1,1),xy(1,2),'x','LineWidt
h',2,'Color','red');
plot(xy(2,1),xy(2,2),'x','LineWidt
h',2,'Color','red');
len=norm(lines(k).point1 -
lines(k).point2);
end

%%%%%%%%%Fibra6%%%%%%%%%

T = graythresh(F6);
T= (1.10)*T;
bw=im2bw(F6,T);
se = strel('disk',1);
bw2 = imerode(bw,se);

B= bwareaopen(bw2,10);

se1 = strel('line',100,45)
bw = imdilate(B,se1);

[H,T,R]=hough (bw);
P=houghpeaks(H,1);

lines=houghlines(bw,T,R,P);
subplot(1,6,6)
imshow(F6);title('F6'); hold on
max_len=0;

for k=1:length(lines)
xy=[lines(k).point1;
lines(k).point2];
plot(xy(:,1),xy(:,2),'LineWidth',2
,'Color','red');
plot(xy(1,1),xy(1,2),'x','LineWidt
h',2,'Color','red');
plot(xy(2,1),xy(2,2),'x','LineWidt
h',2,'Color','red');
len=norm(lines(k).point1 -
lines(k).point2);
end

figure(2);
subplot(1,6,1),
imshow(F1);title('F1');
subplot(1,6,2),
imshow(F2);title('F2');
subplot(1,6,3),
imshow(F3);title('F3');
subplot(1,6,4),
imshow(F4);title('F4');
subplot(1,6,5),
imshow(F5); title('F5');
subplot(1,6,6),
imshow(F6);title('F6');

```

GRADES

```
%%%%%%%%%%GRADES%%%%%%%%%%
G1=imcrop(I,[1632,920,170,170]);
G2=imcrop(I,[2022,920,170,170]);
G3=imcrop(I,[2406,920,170,170]);
G4=imcrop(I,[2784,920,170,170]);

%%%%%%%%%% GRADE 1%%%%%%%%%%
CA=imadjust(G1);
J2=im2bw(CA);
JM=imcomplement(J2);
SE=strel('disk',10);
FO=imopen(JM,SE);
IM=imclearborder(FO,4);
T = bwareaopen(IM,90);
J3=im2bw(CA,0.80);
IF=T|J3;
CAD=im2double(CA);
IFD=im2double(IF);
PROD=CAD.*IFD;
figure,imshow(PROD)

offsets0 = [zeros(170,1)
(1:170)'];
glcms1 =
graycomatrix(PROD,'Offset',offsets0)
stats1 =
graycoprops(glcms1,'Contrast
Correlation Energy Homogeneity ');

%%%%%%%%%% GRADE 2%%%%%%%%%%
CA=imadjust(G2);
J2=im2bw(CA);
JM=imcomplement(J2);
SE=strel('disk',10);
FO=imopen(JM,SE);
IM=imclearborder(FO,4);
T = bwareaopen(IM,90);
J3=im2bw(CA,0.80);
IF=T|J3;
CAD=im2double(CA);
IFD=im2double(IF);
PROD=CAD.*IFD;
figure ,imshow(PROD)

offsets0 = [zeros(170,1)
(1:170)'];
glcms2 =
graycomatrix(PROD,'Offset',offsets0)
stats2 =
graycoprops(glcms2,'Contrast
Correlation Energy Homogeneity ');

%%%%%%%%%% GRADE 3%%%%%%%%%%
CA=imadjust(G3);
J2=im2bw(CA);
```

```
JM=imcomplement(J2);
SE=strel('disk',10);
FO=imopen(JM,SE);
IM=imclearborder(FO,4);
T = bwareaopen(IM,90);
J3=im2bw(CA,0.80);
IF=T|J3;
CAD=im2double(CA);
IFD=im2double(IF);
PROD1=CAD.*IFD;
figure,imshow(PROD)

offsets0 = [zeros(170,1)
(1:170)'];
glcms3 =
graycomatrix(PROD1,'Offset',offsets0)
stats3 =
graycoprops(glcms3,'Contrast
Correlation Energy Homogeneity ');

%%%%%%%%%% GRADE 4%%%%%%%%%%
CA=imadjust(G4);
J2=im2bw(CA);
JM=imcomplement(J2);
SE=strel('disk',10);
FO=imopen(JM,SE);
IM=imclearborder(FO,4);
T = bwareaopen(IM,90);
J3=im2bw(CA,0.80);
IF=T|J3;
CAD=im2double(CA);
IFD=im2double(IF);
PROD=CAD.*IFD;
figure,imshow(PROD)

offsets0 = [zeros(170,1)
(1:170)'];
glcms4 =
graycomatrix(PROD,'Offset',offsets0)
stats4 =
graycoprops(glcms4,'Contrast
Correlation Energy Homogeneity ');

figure,
plot([stats1.Correlation]);
xlabel('Desplazamento Horizontal
Grade 1')
ylabel('Correlação')

figure,
plot([stats2.Correlation]);
xlabel('Desplazamento Horizontal
Grade 2')
ylabel('Correlação')
```

```
figure,
plot([stats3.Correlation]);
xlabel('Desplazamento Horizontal
Grade 3')
ylabel('Correlação')
```

```
figure,
plot([stats4.Correlation]);
xlabel('Desplazamento Horizontal
Grade 4')
ylabel('Correlação')
```

DISCOS CNR

```
f=imread('D:\cmvb\Desktop\IMAGES\M
G\ImageTeste\PH MAMA 28KV W-RH TF
ROW');
```

```
%%%%%%%%DISCO 1 %%%%%%%%%
%Seleção da região do Disco 1
D1=imcrop(f, [2550,1630,75,75]);
S1D1 = mean2(D1);
D11=imcrop(f, [2700,1630,75,75]);
S2D1 = mean2(D11);
N2D1=std2(D11);
```

```
CNRD1=(S1D1-S2D1)/N2D1;
SNRD1=S1D1/N2D1;
CNRD1rel=(S1D1-S2D1)*100/S2D1;
```

```
%%%%%%%%DISCO 2 %%%%%%%%%
%Seleção da região do Disco 2
D2=imcrop(f, [2550,1930,75,75]);
S1D2 = mean2(D2);
D22=imcrop(f, [2700,1930,75,75]);
S2D2 = mean2(D22);
N2D2=std2(D22);
```

```
CNRD2=(S1D2-S2D2)/N2D2;
SNRD2=S1D2/N2D2;
CNRD2rel=(S1D2-S2D2)*100/S2D2;
```

```
%%%%%%%%DISCO 3 %%%%%%%%%
%Seleção da região do Disco 3
D3=imcrop(f, [2550,2170,75,75]);
S1D3 = mean2(D3);
D33=imcrop(f, [2700,2170,75,75]);
S2D3 = mean2(D33);
N2D3=std2(D33);
```

```
CNRD3= abs(S1D3-S2D3)/N2D3;
SNRD3=S1D3/N2D3;
CNRD3rel=(S1D3-S2D3)*100/S2D3;
```

```
%%%%%%%%DISCO 4 %%%%%%%%%
%Seleção da região do Disco 4
D4=imcrop(f, [2550,2420,75,75]);
```

```
S1D4 = mean2(D4);
D44=imcrop(f, [2700,2420,75,75]);
S2D4 = mean2(D44);
N2D4=std2(D44);
```

```
CNRD4=(S1D4-S2D4)/N2D4;
SNRD4=S1D4/N2D4;
CNRD4rel=(S1D4-S2D4)*100/S2D4;
```

```
%%%%%%%%DISCO 5 %%%%%%%%%
%Seleção da região do Disco 5
D5=imcrop(f, [2550,2660,75,75]);
S1D5 = mean2(D5);
D55=imcrop(f, [2700,2660,75,75]);
S2D5 = mean2(D55);
N2D5=std2(D55);
```

```
CNRD5=(S1D5-S2D5)/N2D5;
SNRD5=S1D5/N2D5;
CNRD5rel=(S1D5-S2D5)*100/S2D5;
```

```
%%%%%%%%DISCO 6 %%%%%%%%%
%Seleção da região do Disco 6
D6=imcrop(f, [2550,3000,75,75]);
S1D6 = mean2(D6);
D66=imcrop(f, [2700,3000,75,75]);
S2D6 = mean2(D66);
N2D6=std2(D66);
```

```
CNRD6=(S1D6-S2D6)/N2D6;
SNRD6=S1D6/N2D6;
CNRD6rel=(S1D6-S2D6)*100/S2D6;
```

```
%%%%%%%%DISCO 7 %%%%%%%%%
%Seleção da região do Disco 7
D7=imcrop(f, [2550,3200,75,75]);
S1D7 = mean2(D7);
D77=imcrop(f, [2700,3200,75,75]);
S2D7 = mean2(D77);
N2D7=std2(D77);
```

```
CNRD7=(S1D7-S2D7)/N2D7;
SNRD7=S1D7/N2D7;
CNRD7rel=(S1D7-S2D7)*100/S2D7;
```

```
%%%%%%%%DISCO 8 %%%%%%%%%
%Seleção da região do Disco 8
D8=imcrop(f, [2550,3500,75,75]);
S1D8 = mean2(D8);
D88=imcrop(f, [2700,3500,75,75]);
S2D8 = mean2(D88);
N2D8=std2(D88);
```

```
CNRD8=(S1D8-S2D8)/N2D8;
SNRD8=S1D8/N2D8;
CNRD8rel=(S1D8-S2D8)*100/S2D8;
```