



Universidade Federal de Pernambuco
Programa de Pós Graduação em Engenharia Mecânica

**Desenvolvimento e implementação de uma
ferramenta computacional de uso médico para
análise de imagens termográficas**

Kamila Fernanda Ferreira da Cunha Queiroz

Recife
2016

KAMILA FERNANDA FERREIRA DA CUNHA QUEIROZ

**Desenvolvimento e implementação de uma ferramenta computacional de
uso médico para análise de imagens termográficas**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Mecânica, PPGEM, da Universidade Federal de Pernambuco como parte dos requisitos necessários à obtenção do grau de Mestre em Engenharia Mecânica.

Área de concentração: Processos e Sistemas Térmicos

Orientadora: Rita de Cássia Fernandes de Lima.

Co-orientador: Marcus Costa de Araújo

Recife

2016

Q3d

Queiroz, Kamila Fernanda Ferreira da Cunha.

Desenvolvimento e implementação de uma ferramenta computacional de uso médico para análise de imagens termográficas / Kamila Fernanda Ferreira da Cunha Queiroz - 2016.

104 folhas. Il., Abr.; Sigl.; Sim. e Tabs.

Orientadora: Prof^a. Dr^a. Rita de Cássia Fernandes de Lima.

Co-orientador: Prof^o. Dr^o. Marcus Costa de Araújo.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Mecânica, 2016.

Inclui Referências e Anexos.

1. Engenharia Mecânica. 2. Termografia. 3. Detecção do câncer de mama. 4. Sistemas de CAD. 5. GUI. 6. Classificação. I. Lima, Rita de Cássia Fernandes de (Orientadora). II. Araújo, Marcus Costa de (Co-orientador). III. Título.

UFPE

621 CDD (22. ed.)

BCTG/2016 - 139

19 de fevereiro de 2016.

“DESENVOLVIMENTO E IMPLEMENTAÇÃO DE UMA FERRAMENTA
COMPUTACIONAL DE USO MÉDICO PARA ANÁLISE DE IMAGENS
TERMOGRÁFICAS”

KAMILA FERNANDA FERREIRA DA CUNHA QUEIROZ

ESTA DISSERTAÇÃO FOI JULGADA ADEQUADA PARA OBTENÇÃO DO
TÍTULO DE MESTRE EM ENGENHARIA MECÂNICA

ÁREA DE CONCENTRAÇÃO: PROCESSOS E SISTEMAS TÉRMICOS

APROVADA EM SUA FORMA FINAL PELO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
MECÂNICA/CTG/EEP/UFPE

Profª Drª RITA DE CÁSSIA FERNANDES DE LIMA
ORIENTADORA/PRESIDENTE

Prof. Dr. MARCUS COSTA DE ARAÚJO
CO-ORIENTADOR

Prof. Dr. JORGE RECARTE HENRÍQUEZ
GUERRERO
COORDENADOR DO PROGRAMA

BANCA EXAMINADORA:

Profª Drª RITA DE CÁSSIA FERNANDES DE LIMA (UFPE)

Prof. Dr. MARCUS COSTA DE ARAÚJO (UFPE)

Prof. Dr. WELLINGTON PINHEIRO DOS SANTOS (UFPE)

Profª Drª LUCIETE ALVES BEZERRA (UFPE)

AGRADECIMENTOS

Agradeço a Deus pelas oportunidades que Ele tem me proporcionado e por me iluminar em todos os momentos, sendo a mão segura que me guia e me sustenta. Aos meus pais que educaram a mim e ao meu irmão com amor e nunca mediram esforços para nos fornecer uma educação de qualidade.

Ao meu irmão, Reginaldo Júnior, por toda ajuda, incentivo e conselhos durante o mestrado. Aos meus avós pelos ensinamentos, preocupação e por sempre acreditarem no meu potencial. Ao meu noivo, Rodrigo Antônio, por todo apoio, pela compreensão e pela enorme paciência.

Agradeço a minha orientadora, Professora Rita, pela confiança no meu trabalho, pela amizade, pelo incentivo e pela orientação precisa no momento certo. Ao meu co-orientador, Professor Marcus, pela ajuda e dicas importantes para o desenvolvimento da dissertação.

Ao Professor Charamba e à Professora Luciete pela contribuição no seminário e na organização do trabalho. Ao Dr. Francisco George, médico do Ambulatório de Mastologia do Hospital das Clínicas da UFPE, pela participação e apoio fundamentais para o andamento deste projeto de pesquisa.

Aos amigos do LABTERMO pelo companheirismo, pelos sorrisos compartilhados e pelo apoio em todos os momentos. Há amizades que se constroem de maneira inexplicável e dão força no dia-a-dia.

Ao Programa de Pós-Graduação em Engenharia Mecânica pela oportunidade e por fornecer os recursos necessários para o desenvolvimento desta dissertação.

Ao CNPq pelo apoio financeiro concebido, o qual viabilizou a realização deste trabalho.

“Não vos conformeis com este mundo, mas transformai-vos pela renovação do vosso espírito, para que possais discernir qual é a vontade de Deus, o que é bom, o que Lhe agrada e o que é perfeito.”

São Paulo (Romanos 12, 2)

RESUMO

A inspeção termográfica tem emergido como um método potencial para melhorar a eficiência da detecção precoce do câncer de mama. A técnica não utiliza radiação ionizante e possui a vantagem de facilitar a realização de exames de mama em homens e detectar alterações nas mamas de mulheres mais jovens. Sistemas de diagnóstico auxiliado por computador (CAD) são métodos importantes no subsídio à decisão médica e são usados para melhorar a consistência da interpretação das imagens. Normalmente, estes sistemas são associados a interfaces gráficas para facilitar o trabalho dos usuários e tornar o programa desenvolvido acessível a pesquisadores e/ou médicos ligados à área. O objetivo desta dissertação é desenvolver uma interface gráfica de usuário (GUI – *Graphical User Interface*) prática e que possibilite a detecção de anormalidades a partir de termogramas de mamas. Para isto foram implementados sistemas de CAD baseados em classificadores estatísticos, além de análises relacionadas ao quantitativo de casos clínicos e sua relação com a idade das pacientes. As regiões de interesse foram segmentadas tanto de forma semiautomática quanto de forma automática, as quais estão associadas, respectivamente, ao classificador SVM (*Support Vector Machine*) e ao classificador baseado na distância de Mahalanobis. Com o intuito de identificar as anormalidades das mamas, participaram noventa e oito pacientes do Hospital das Clínicas da Universidade Federal de Pernambuco, as quais serviram para construir a base de dados para a classificação individual de determinada paciente. A eficácia da classificação para esta amostra foi medida através da sensibilidade e da especificidade ao grupo Maligno, e das taxas de acerto das classes Benigno, Cisto e Normal. A GUI desenvolvida foi avaliada através do estudo das imagens termográficas de cinco pacientes pertencentes às diferentes classes. No presente trabalho, apresentam-se resultados para o classificador Mahalanobis e para o classificador SVM, além de suas variações.

Palavras-chave: Termografia. Detecção do Câncer de Mama. Sistemas de CAD. GUI. Classificação.

ABSTRACT

The infrared thermography has emerged as a potential method to improve the efficiency of the early detection of the breast cancer. This technique does not use ionizing radiation and is also suitable to breast screening in men, as well as is able to detect changes in the younger women's breasts. Computer-aided diagnosis (CAD) systems are important to medical decision and are used to improve image interpretation. Typically, these systems are associated with graphical interfaces to facilitate users' work. Furthermore the developed framework can be an important tool (GUI - Graphical User Interface) for the people interested in breast abnormalities detection. In the sense, the CAD systems were implemented based on statistical classifiers. Some statistical analyses associated to quantitative clinical cases were performed. The relation to patients' age was also analyzed. The regions of interest were segmented in automatic and semiautomatic manners, which are respectively associated with the SVM (Support Vector Machine) classifier and the Mahalanobis classifier. Ninety eight patients images from the Hospital das Clínicas (HC) of Federal University of Pernambuco (UFPE) participated in the tests. The classification efficiency for this sample was measured using the sensitivity and the specificity to the malignant group, and to the accuracy of classifying the classes: Benign, Cyst and Normal. The GUI created was evaluated through the study of thermographic images of five patients with the different referred classes. In the present work, the results for the Mahalanobis classifier and SVM classifier are presented.

Keywords: Thermography. Breast Cancer Detection. CAD System. GUI. Classification.

LISTA DE FIGURAS

Figura 1 – Taxa de mortalidade por câncer de mama na população feminina brasileira, específicas por faixas etárias, por 100.000 mulheres.	17
Figura 2 – Janelas da GUI com exemplos de visualização do sinal de ECG segmentado, do gráfico de desvio do segmento ST e dos intervalos R-R no tempo.	34
Figura 3 – Detalhes da interface gráfica criada.	35
Figura 4 – Tela principal (Menu Arquivo).	36
Figura 5 – GUI do sistema proposto.	37
Figura 6 – Interface gráfica Perímetro.	38
Figura 7 – Interface gráfica AVMTM (Menu Arquivo).	39
Figura 8 – Fluxograma de sistemas CADe e CADx.	41
Figura 9 – Imagens termográficas com limites diferentes de temperatura.	42
Figura 10 – Aprendizado de máquina supervisionado.	46
Figura 11 – Janela de ferramentas <i>guide</i>	50
Figura 12 – Diagrama simplificado da metodologia adotada.	52
Figura 13 – Aparato mecânico.	53
Figura 14 – Resultado da segmentação automática.	55
Figura 15 – Resultado da segmentação semiautomática.	56
Figura 16 – Representação de algumas características definidas a partir das temperaturas máximas e mínimas da mama esquerda e da mama direita.	57
Figura 17 – Interface gráfica Analise IR_MAMA.	64
Figura 18 – Menu File/Help.	64
Figura 19 – Painel Informações do Paciente.	65
Figura 20 – Painel Segmentação.	65
Figura 21 – Painel Estatística.	65
Figura 22 – Painel Resultado.	66
Figura 23 – Botões de acionamento da interface gráfica.	67
Figura 24 – Histogramas para seleção de características (Vermelho – Câncer / Azul – Não-Câncer).	68
Figura 25 – Espaço de características usado para seleção da melhor combinação.	70
Figura 26 – Representação dos histogramas.	72
Figura 27 – Método <i>one-versus-all</i>	74

Figura 28 – Dados da Paciente 1.	77
Figura 29 – Regiões segmentadas da Paciente 1.	78
Figura 30 – Resultado da Paciente 1 usando o classificador SVM.	79
Figura 31 – Resultado da Paciente 1 usando o classificador Mahalanobis	79
Figura 32 – Imagem salva da Paciente 1 com o resultado do classificador SVM.....	80
Figura 33 – Dados da Paciente 2.	80
Figura 34 – Regiões segmentadas da Paciente 2.	81
Figura 35 – Resultado da Paciente2 usando o classificador SVM.	82
Figura 36 – Resultado da Paciente 2 usando o classificador Mahalanobis	82
Figura 37 – Imagem salva da Paciente 2 com o resultado do classificador SVM.....	82
Figura 38 – Dados da Paciente 3.	83
Figura 39 – Regiões segmentadas da Paciente 3.	83
Figura 40 – Resultado da Paciente 3 usando o classificador SVM.	84
Figura 41 – Resultado da Paciente 3 usando o classificador Mahalanobis	84
Figura 42 – Imagem salva da Paciente 3 com o resultado do classificador SVM.....	85
Figura 43 – Dados da Paciente 4.	85
Figura 44 – Regiões segmentadas da Paciente 4.	86
Figura 45 – Resultado da Paciente 4 usando o classificador SVM.	87
Figura 46 – Resultado da Paciente 4 usando o classificador Mahalanobis	87
Figura 47 – Imagem salva da Paciente 4 com o resultado do classificador SVM.....	87
Figura 48 – Dados da Paciente5.	88
Figura 49 – Resultado da Paciente5 usando o classificador SVM.	88
Figura 50 – Gráficos pizzas de distribuição de casos clínicos	89
Figura 51 – Histogramas Idade × Frequência de cada caso clínico.	90
Figura 52 – Tela do menu Help.....	91
Figura 53 – Ficha Anamnese (página frontal).	101
Figura 54 – Ficha Anamnese (página posterior).	102
Figura 55 – Termo de consentimento livre e esclarecido.	103
Figura 56 – Planilha onde se anotam as numerações das imagens termográficas e outras informações pertinentes.....	104

LISTA DE TABELAS

Tabela 1 – Classificação BI-RADS.	18
Tabela 2 – Sistemas de CAD analisados.	33
Tabela 3 – Base de dados de imagens termográficas.	54
Tabela 4 – Classificação THS.	66
Tabela 5 – Lista de características.	67
Tabela 6 – <i>Ranking</i> das melhores características.	69
Tabela 7 – Resultados da classificação para os conjuntos de características $[c3, c11]$ e $[c5, c6]$, com <i>kernel</i> 7.	71
Tabela 8 – Resultados da classificação para um polinômio de ordem 8.	71
Tabela 9 – Comparação entre os classificadores SVM, com <i>kernel</i> 8, e Mahalanobis.	73
Tabela 10 – Resultado da classificação SVM/OVA, com <i>kernel</i> 8.	75
Tabela 11 – Resultado da classificação Mahalanobis CC.	76
Tabela 12 – Resultados obtidos na classificação das pacientes estudadas.	89

LISTA DE ABREVIATURAS E SIGLAS

BI-RADS	Breast Imaging Reporting and Data System
BHTE	Bioheat Transfer Equation
CAD	Computer-Aided Diagnosis
DATASUS	Departamento de Informática do Sistema Único de Saúde
GUI	Graphical User Interface
HC	Hospital das Clínicas
HUAP	Hospital Universitário Antônio Pedro
INCA	Instituto Nacional do Câncer
OMS	Organização Mundial de Saúde
OVA	One – versus – all
ROI	Region Of Interest
SVM	Support Vector Machine
TCLE	Termo de Consentimento Livre e Esclarecido
THS	Thermal Statistical Index
UFF	Universidade Federal Fluminense
UFPE	Universidade Federal de Pernambuco
WEKA	Waikato Environment for Knowledge Analysis

LISTA DE SÍMBOLOS

c	Calor específico ($\text{J kg}^{-1} \text{K}^{-1}$)
FN	Falso negativo
FP	Falso positivo
k	Condutividade térmica ($\text{W m}^{-1} \text{K}^{-1}$)
K	Kernel
M_{MD}	Matriz morfológica da mama direita
M_{ME}	Matriz morfológica da mama esquerda
Q	Taxa volumétrica de geração de calor devido à fonte externa (W m^{-3})
Q_m	Taxa volumétrica de geração de calor metabólico (W m^{-3})
Q_p	Taxa volumétrica de geração de calor devido à perfusão sanguínea (W m^{-3})
t	Tempo (s)
$\mathbf{T}$	Matriz de temperaturas
T	Temperatura (K)
T_a	Temperatura do sangue arterial (K)
$T_{m\acute{a}x}$	Limite superior do intervalo de temperatura
$T_{m\acute{i}n}$	Limite inferior do intervalo de temperatura
T_v	Temperatura do sangue venoso (K)
VN	Verdadeiro negativo
VP	Verdadeiro positivo

Subscritos

a	arterial
i	i-ésima classe
MD	mama direita
ME	mama esquerda
max	máximo
min	mínimo
s	sangue
t	tecido
v	venoso

Símbolos Gregos

ρ	Massa específica (kg m^{-3})
ω	Taxa de perfusão sanguínea (s^{-1})
∇	Operador nabla

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Motivação	16
1.2	Objetivos.....	20
1.2.1	Objetivo geral	20
1.2.2	Objetivos específicos	21
1.3	Organização do Trabalho	21
2	REVISÃO BIBLIOGRÁFICA	23
2.1	Conceitos de Transferência de Calor no Corpo Humano	23
2.2	Termografia na Área Médica	25
2.3	Sistemas CAD Aplicados às Imagens Térmicas de Mama	28
2.4	Interfaces Gráficas Relacionadas e Não Relacionadas à Termografia	33
3	FUNDAMENTAÇÃO TEÓRICA.....	40
3.1	Uso do Computador no Apoio ao Diagnóstico Médico.....	40
3.1.1	Processamento da imagem termográfica	42
3.1.2	Classificação	45
3.2	Interfaces Gráficas de Usuários – Plataforma Matlab®	48
4	METODOLOGIA.....	52
4.1	Aquisição e Armazenamento de Termogramas	52
4.2	Base de Dados.....	54
4.3	Segmentação	55
4.4	Extração de Características	56
4.5	Classificação	58
4.6	Ajustes dos Métodos de Análise	61
5	RESULTADOS E DISCUSSÃO	52
5.1	Interface Gráfica	52

5.2	Análise Quantitativa dos Sistemas de CAD	67
5.3	Estudo de Casos	76
5.2.1	Estudo de caso 1: paciente normal	77
5.2.2	Estudo de Caso 2: paciente com tumor benigno.....	80
5.2.3	Estudo de Caso 3: paciente com cisto	83
5.2.4	Estudo de Caso 4: pacientes com tumor maligno.....	85
5.4	Painel Estatística e Função Help.....	89
6	CONCLUSÕES E TRABALHOS FUTUROS.....	92
	REFERÊNCIAS BIBLIOGRÁFICAS	94
	ANEXOS	101

1 INTRODUÇÃO

1.1 Motivação

O estudo do corpo humano, em algumas de suas formas e propósitos, constitui uma importante ligação entre a medicina e alguns campos da engenharia (PEREIRA, 2013). Diversos fenômenos e funções do corpo podem ser modelados e analisados pelos métodos de engenharia, por exemplo: a troca de energia térmica entre o sangue em escoamento e o tecido circundante; a cinemática do movimento humano; o esqueleto funcionando como uma estrutura e o coração funcionando como uma bomba hidráulica.

Além daqueles fenômenos, é possível simular alguns procedimentos médicos tanto cirúrgicos como terapêuticos. Ferramentas numéricas computacionais usuais da engenharia podem fornecer subsídios para tornar tais procedimentos mais seguros e eficazes.


Os mecanismos citados podem buscar soluções seguras para os diagnósticos e para prevenção de doenças, de maneira direta ou indireta. Dentre as diversas aplicações da engenharia, destacam-se: o projeto de novos equipamentos, atrelado ao desenvolvimento de novas formas de diagnóstico; análise de sinais biológicos; processamento de imagens médicas; usinagem e projeto de próteses (ARAÚJO, 2014).

O desenvolvimento de técnicas que auxiliem no diagnóstico precoce do câncer é uma área da medicina que pode se beneficiar dos métodos da engenharia mencionados. A detecção precoce do câncer de mama torna-se importante, pois é a neoplasia maligna de maior incidência sobre a população feminina mundial (INCA, 2014).

No Brasil, o câncer de mama é o segundo mais frequente e a maior causa de morte entre as mulheres (DOURADO NETO, 2014), com 14.207 mortes no ano de 2013 e uma estimativa de 57.120 novos casos esperados para o ano de 2015. Este tipo de câncer também acomete homens, mas apenas representa 1% do total de casos da doença (INCA, 2015).

Para o câncer de mama, a idade é um dos principais fatores de risco. O processo de envelhecimento vem acompanhado de alterações biológicas e do acúmulo de exposições à radiação ao longo da vida, fatos que aumentam a probabilidade de se desenvolver o referido câncer. Conforme pode ser observado na Figura 1, mulheres com idade superior a 50 anos são mais predispostas a desenvolver a doença, aumentando a taxa de mortalidade a partir dessa idade.

Figura 1 – Taxa de mortalidade por câncer de mama na população feminina brasileira, específicas por faixas etárias, por 100.000 mulheres.



Fonte: Sistema de Informação de Mortalidade/DATASUS.

A Organização Mundial de Saúde (OMS) afirma que o câncer de mama identificado em estágios iniciais (lesões menores que dois centímetros de diâmetro) apresenta prognóstico mais favorável e alto percentual de cura. As estratégias para a prévia detecção são o rastreamento e diagnóstico precoce.

O diagnóstico precoce necessita da conscientização da população e de profissionais de saúde para os sinais e sintomas antecipados do câncer, promovendo a realização de atendimento médico regular para os pacientes avaliados (SILVA & HORTALE, 2012). Estes mecanismos são importantes para o controle da doença.

O rastreamento significa submeter indivíduos assintomáticos a exames de triagem para detectar o câncer (ou lesões sugestivas de câncer) e encaminhar a população, que apresente resultados alterados, para confirmação de diagnóstico e tratamento. Ele pode ser oportunístico - quando é realizado por ocasião de uma consulta médica - ou organizado - quando existe busca ativa da população alvo (SILVA & HORTALE, 2012).

Algumas técnicas têm sido comumente usadas no rastreamento do câncer de mama. Entre elas encontram-se: mamografia por filme radiológico, mamografia digital de campo total, detecção assistida por computador, ultrassonografia, imagem por ressonância magnética,

tomografia por emissão de pósitron (PET), termografia, imagem por impedância elétrica (DIAKIDES et al., 2006).

A mamografia é o principal método de rastreamento por imagens utilizado para diagnosticar esse tipo de câncer. O exame consiste da emissão de feixe de Raios-X de baixa dosagem, gerando uma imagem da mama (ARAÚJO, 2014). Esta técnica, porém, pode ser ineficiente para mulheres com mamas fibrocísticas, densas ou cirurgicamente implantadas (OLIVEIRA, 2012). Além disso, há o perigo do uso da radiação ionizante e o desconforto gerado pela compressão das mamas entre as superfícies planas para melhorar a qualidade da imagem (NG et al., 2005 apud QUEIROZ, 2014).

Normalmente, mulheres muito jovens não são submetidas à mamografia por possuírem tecido mamário bastante denso, o que interfere na acurácia do exame tornando difícil a visualização das anormalidades. Assim, a mamografia é recomendada para mulheres com mais de 40 anos (UDESC, 2007 apud BEZERRA, 2013), ou antes, caso seja detectado algum achado pelo médico ou a paciente pertença a um grupo de risco.

A sensibilidade e a especificidade da mamografia são diretamente influenciadas por características da paciente (idade, por exemplo) e do próprio tumor. De acordo com o INCA (2007), o exame tem sensibilidade entre 88% e 93,1% e especificidade entre 85% e 94,2%.

O laudo mamográfico adota as orientações do Colégio Americano de Radiologia que classifica os resultados do exame conforme o sistema *Breast Imaging Reporting and Data System* (BI-RADS®), sintetizados na Tabela 1.

Tabela 1 – Classificação BI-RADS.

Classificação	Avaliação	Descrição	Recomendação
BI-RADS 0	Incompleto	Inconclusiva	Realizar novos exames
BI-RADS 1	Negativo	Nada a comentar	Rastreamento de rotina
BI-RADS 2	Benigno	Achado benigno	Rastreamento de rotina
BI-RADS 3	Provavelmente benigno	Achado com alta probabilidade de benignidade (>95%)	Acompanhamento em 6 meses
BI-RADS 4	Anormalidade suspeita	Razoável probabilidade de malignidade	Biópsia deve ser considerada
BI-RADS 5	Altamente suspeito de malignidade	Achado com alta probabilidade de malignidade (>95%)	Realizar ações apropriadas
BI-RADS 6	Malignidade comprovada por biópsia	Achado maligno sendo visualizado para tratamento	Tratamento

Fonte: DOURADO NETO, 2014.

A inspeção termográfica tem emergido como um método potencial para melhorar a eficiência da detecção precoce de doenças na mama (KAPOOR; PRASAD; PATNI, 2012; BORCHARTT, 2013; ARAÚJO, 2014). Baseia-se no princípio de que as temperaturas em torno do tecido mamário que apresenta algum tipo de anomalia são maiores do que as do tecido normal (ACHARYA et al., 2014). Segundo Ng e Sudharsan (2004), a termografia associada à mamografia e ao exame clínico aumenta a sensibilidade da detecção do câncer mamário para, aproximadamente, 98%.

A vantagem adicional da termografia, além do fato de não utilizar radiação ionizante, é a facilidade da realização de exames de mama em homens e a detecção de alterações mamárias em mulheres mais jovens que ainda não são submetidas a exames de mamografia pelas questões discutidas anteriormente (QUEIROZ, 2014). Apesar das vantagens citadas, a termografia é considerada como um exame complementar, ainda em estudo (BRIOSCHI, 2011 apud SANTOS, 2014).

As imagens médicas da mama obtidas pelos diferentes tipos de exames apresentam alto grau de informações relevantes para o especialista que realiza a sua análise (BORCHARTT, 2013). Os avanços tecnológicos em áreas como informática, computação gráfica e engenharia permitiram o desenvolvimento de sistemas de diagnóstico auxiliado por computador (CAD – *Computer-Aided Diagnosis*), que tem a função de processar as imagens através de algoritmos pré-definidos disponibilizando informações que forneçam subsídios aos médicos especialistas com objetivo de agilizar e/ou melhorar o diagnóstico (COTRIM; SILVA; BEZERRA, 2007).

Os sistemas de CAD são considerados uma importante ferramenta no auxílio ao diagnóstico médico do câncer de mama. A sua intenção é melhorar a consistência da interpretação das imagens considerando-se a resposta do computador. Esta resposta pode ser útil notadamente quando o diagnóstico de uma doença está relacionado à subjetividade de uma análise visual. Assim, uma dupla leitura por um médico especialista e por um computador pode melhorar significativamente a eficiência do diagnóstico (FURUIE et al., 1999 apud COTRIM; SILVA; BEZERRA, 2007).

Diante da limitação do sistema visual humano e da inexperiência do médico na interpretação de imagens termográficas alguns sistemas de CAD estão sendo desenvolvidos para contribuir na detecção de anomalias mamárias, a fim de investigar a viabilidade do uso da termografia como exame de triagem na mastologia (BORCHARTT, 2013; DOURADO NETO, 2014).

Normalmente, sistemas de CAD são associados a interfaces gráficas para facilitar o trabalho dos usuários. Uma das principais vantagens de criar uma interface gráfica de usuário (GUI – *Graphical User Interface*) é tornar o programa desenvolvido acessível para uma pessoa sem conhecimento prévio da linguagem de programação (KAPOOR; PRASAD; PATNI, 2012). E, neste caso, por incorporar os sistemas de CAD, estas interfaces homem-computador possuem grande valor prático no diagnóstico de anormalidades da mama através de termogramas. A GUI mais conhecida atualmente é a do *software* Matlab[®].

Há poucos trabalhos na literatura que desenvolveram uma GUI para determinado sistema de diagnóstico auxiliado por computador usando imagens termográficas. E, aqueles que a fizeram, não realizaram um estudo efetivo de sua aplicação na triagem de pacientes nem foi relatada sua disponibilização aos médicos especialistas para que esses a utilizassem como uma ferramenta adicional e inovadora de detecção de câncer de mama.

A dissertação desenvolvida está inserida no projeto de pesquisa denominado “**Análise da viabilidade do uso de câmera termográfica como ferramenta auxiliar no diagnóstico de câncer de mama em hospital público localizado em clima tropical**”, que foi aprovado pelo Comitê de Ética da Universidade Federal de Pernambuco (UFPE) - Brasil, e registrado no Ministério da Saúde sob o nº CEP/CCS/UFPE N°279/05, e que se encontra em andamento desde novembro de 2005. Recentemente, os apoios financeiros do referido projeto foram obtidos pelos seguintes projetos:

- “Validação do uso de imagens médicas termográficas como ferramenta auxiliar de detecção precoce de câncer de mama através de simulação computacional e como elemento de triagem em populações de baixa renda residentes em áreas rurais”. (CNPq Universal 2013).
- “Análise de termogramas de mama por meio de técnicas de simulação numérica e otimização.” (CNPq Universal 2014).

1.2 Objetivos

1.2.1 Objetivo geral

O presente trabalho tem por objetivo a elaboração de uma interface gráfica para uso médico na análise de termogramas de mama, com o intuito de ser utilizada como ferramenta de triagem de pacientes e de auxílio ao diagnóstico do câncer de mama.

1.2.2 Objetivos específicos

- Avaliar os sistemas de CAD desenvolvidos por Araújo (2014) e Dourado Neto (2014) para uma base de dados ampliada;
- Incluir a classe Normal ao classificador proposto por Araújo (2014);
- Extrair novas características para a amostra que será avaliada, que servirão de entrada para o processo de classificação proposto pelos autores citados anteriormente;
- Implementar a técnica *one-versus-all* ao classificador binário SVM (*Support Vector Machine*), a fim de se obter uma análise multiclass;
- Ajustar as técnicas utilizadas para que uma paciente seja avaliada individualmente quanto à presença ou não de distúrbios mamários;
- Propor um novo índice (THS – *Thermal Statistical Index*) baseado em imagens termográficas e em classificadores estatísticos, para indicar as possíveis ocorrências de patologias mamárias;
- Criar uma interface gráfica amigável que permita a um pesquisador ou médico mastologista avaliar de forma simples e rápida uma anomalia mamária, a partir de uma imagem termográfica.

1.3 Organização do Trabalho

Este trabalho está dividido em seis principais capítulos. No capítulo 1 foi apresentada uma introdução que engloba a motivação e os objetivos fundamentais do projeto desenvolvido.

No Capítulo 2 é apresentada uma revisão bibliográfica que aborda os conceitos de transferência de calor no corpo humano, alguns conceitos e aplicações da termografia na área médica e alguns estudos de sistemas de CAD utilizando imagens térmicas. Também foi discutido o uso da interface gráfica de usuário (GUI) relacionada e não relacionada à termografia.

No Capítulo 3, é apresentado o uso do computador no apoio ao diagnóstico médico, abordando o processamento da imagem por infravermelho e os conceitos de classificação. Além disso, o *software* Matlab[®] será brevemente explicado, especialmente seu funcionamento como uma GUI.

No Capítulo 4 é descrita a metodologia adotada para o desenvolvimento do projeto. Esta metodologia é dividida nas seguintes etapas: aquisição e armazenamento da imagem termográfica; estabelecimento de uma nova base de dados; segmentação automática e semiautomática das regiões de interesse; extração de características; classificação e ajustes dos métodos de análise para implementação na interface gráfica.

Já no Capítulo 5 é apresentada a interface gráfica desenvolvida, uma análise quantitativa dos sistemas de CAD utilizados e são discutidos alguns resultados dos estudos de casos realizados usando-se a GUI. Por fim, o Capítulo 6 fornece as considerações finais e as sugestões para trabalhos futuros, seguido pelas Referências Bibliográficas e pelo Apêndice.

2 REVISÃO BIBLIOGRÁFICA

2.1 Conceitos de Transferência de Calor no Corpo Humano

O ser humano é homeotérmico, ou seja, possui a capacidade de manter sua temperatura corporal em torno de 37 °C, apesar das variações nas condições ambientais e nas tensões térmicas que é submetido. O equilíbrio térmico é conseguido através do balanço entre a perda e a produção ou obtenção de calor.

Diversos modelos foram desenvolvidos para analisar a transferência de calor em seres vivos, dentre estes os principais são: o modelo de Pennes, o modelo de Wulff, o modelo de Klinger, o modelo de Chen e Holmes, o modelo dos vasos emparelhados e o modelo de Weinbaum, Jiji e Lemons. Silva (2012) descreveu em seu trabalho alguns destes modelos.

O modelo desenvolvido por Harry H. Pennes, em 1948, é referência dos modelos térmicos do corpo humano (ALBUQUERQUE NETO, 2010) devido à sua simplicidade e à menor necessidade de parâmetros termofísicos que são, muitas vezes, desconhecidos ou não muito bem determinados (BEZERRA, 2013). Pennes realizou uma modificação na equação da condução de calor, que passou a ser conhecida como “Equação da Biotransferência de Calor”, BHTe (*Bioheat Transfer Equation*) ou como “Equação de Pennes”, para levar em conta a geração de calor metabólica e a troca de energia térmica entre o sangue em escoamento e o tecido circundante (INCROPERA et al., 2008).

Dessa forma, realizando o balanço total de energia para um determinado tecido e desprezando os efeitos químicos, físicos, elétricos e nucleares obtém-se a Equação (2.1) abaixo.

$$\rho_t c_t \frac{\partial T_t}{\partial t} = \nabla \cdot (k_t \nabla T_t) + Q_m + Q_p + Q \quad (2.1)$$

onde:

ρ_t = massa específica do tecido;

c_t = calor específico do tecido;

k_t = condutividade térmica do tecido;

T_t = temperatura do tecido;

t = tempo;

Q_m = taxa volumétrica de geração de calor metabólico;

Q_p = taxa volumétrica de geração/remoção de calor devido à perfusão sanguínea;

Q = taxa volumétrica de geração/remoção de calor, incluindo outras fontes externas.

A fonte de calor devido à perfusão sanguínea pode ser modelada pela seguinte expressão (DILLER,1982 apud BEZERRA, 2013):

$$Q_p = \omega \rho_s c_s (T_a - T_v) \quad (2.2)$$

onde:

ω = taxa de perfusão sanguínea (ml/s de sangue por ml de tecido);

ρ_s = massa específica do sangue;

c_s = calor específico do sangue;

T_a = temperatura do sangue arterial entrando no volume de controle do tecido;

T_v = temperatura do sangue venoso saindo volume de controle do tecido.

Nas equações anteriores, a troca de calor é normalmente considerada completa, isto é, ao sair, assume-se que a temperatura do sangue iguala-se à temperatura do tecido. Assim, considera-se que a geração de calor metabólico, Q_m , é homogeneamente distribuída em todo tecido de interesse como uma taxa de deposição de energia por unidade de volume (QUEIROZ, 2014). Também se considera que o efeito da perfusão é homogêneo e isotrópico, e que a transferência de calor ocorre nos capilares que estão em equilíbrio térmico com os tecidos vizinhos (CHARNY,1992; ETO & RUBINSKY,1996 apud OLIVEIRA, 2012).

Nessa situação, o sangue entra nos capilares com a mesma temperatura do sangue arterial, T_a , nos quais a troca de calor ocorre para que a temperatura do sangue arterial se iguale a do tecido a sua volta. Aqui, supõe-se que não há transferência de energia, tanto antes como após a passagem do sangue pelos capilares, de modo que a temperatura na qual o sangue entra na circulação seja a mesma do tecido local (CHATO,1980 apud QUEIROZ, 2014).

A troca total de energia entre o sangue e o tecido é diretamente proporcional à massa específica, ao calor específico e a taxa de perfusão do sangue através do tecido, e é descrita em termos da troca de calor sensível do sangue, como se pode observar na Equação (2.2). A

principal vantagem do modelo de Pennes (Equação (2.1)) sobre os demais modelos, é que o termo que leva em consideração a perfusão sanguínea varia linearmente com a temperatura (CHATO,1980 apud QUEIROZ, 2014).

2.2 Termografia na Área Médica

O estudo da transferência de calor em tecidos vivos é de grande importância, em razão de a temperatura ser um parâmetro relevante na manutenção da vida. Historicamente, a temperatura tem provado ser um bom indicador de saúde e, desde 400 a.C., ela é usada para o diagnóstico clínico (HOUDAS & RING, 1982; RING, 2007 apud LAHIRI et al., 2012).

Em 1934, Hardy descreveu o papel fisiológico da emissão de radiação infravermelha pelo corpo humano e estabeleceu a importância do diagnóstico a partir da temperatura medida pela técnica de infravermelho, o que possibilitou o uso da termografia nas ciências médicas (HARDY, 1934; HARDY & MUSCHENHEIM, 1936 apud LAHIRI et al., 2012).

Já em 1936, Barnes demonstrou que termogramas podem fornecer informações de anomalias físicas e, assim, ser útil para o diagnóstico de diversas doenças (BARNES, 1963 apud LAHIRI et al., 2012). Porém, o primeiro uso da termografia por infravermelho na medicina foi relatado apenas em 1960 devido à indisponibilidade de equipamentos com qualidade e a falta de conhecimento prático dos técnicos (RING, 2010 apud LAHIRI et al., 2012). Desde então, ela vem mostrando grande potencial neste âmbito e seu uso vem crescendo amplamente.

Atualmente, as imagens termográficas são geradas a partir de uma câmera que é sensível à radiação infravermelha. Os seus sensores captam a radiação térmica gerada pelos objetos, neste caso o corpo humano, que apresentam temperatura acima do zero absoluto (BORCHARTT, 2013). Entretanto, além da radiação devido à temperatura do objeto, chega à câmera a radiação refletida pelo mesmo proveniente de fontes adjacentes e a radiação emitida pela atmosfera.

A fim de manter a correta medição da temperatura de uma superfície pela câmera de infravermelho, é necessário que ela compense todos os efeitos citados anteriormente por meio de correlações matemáticas internas (ARAÚJO,2014). Para tal fim, precisam-se inserir alguns parâmetros: emissividade do objeto; umidade relativa do ar; temperatura refletida (caso haja objetos considerados como fontes de calor) e a distância entre a câmera e o objeto.

As câmeras termográficas têm sido utilizadas com êxito na detecção do câncer de mama, da neuropatia diabética e desordem vascular, no estudo da termorregulação, na triagem da febre, na termoencefaloscopia (imagens cerebrais), na odontologia, na dermatologia, no diagnóstico de doenças reumatológicas e osteomusculares, no diagnóstico da síndrome do olho seco, no tratamento de doenças hepáticas e na detecção de metástase no fígado, na isquemia intestinal, no transplante renal, no tratamento de doenças cardíacas e na ginecologia. As imagens termográficas têm sido usadas, também, no tratamento com acupuntura, na crioterapia, na medicina legal, nas cirurgias plásticas e na avaliação dos danos da radiação no corpo humano (AMMER & RING, 1995; JUNG et al., 2003 apud LAHIRI et al., 2012).

No monitoramento de processos de termorregulação através da termografia, Lahiri et al., (2015) investigaram o aquecimento local da temperatura da região da bochecha e da orelha devido ao uso de celulares. Foi observado que a temperatura do aparelho aumenta exponencialmente quando ele estava desligado e recebendo carga elétrica, simultaneamente. E esta temperatura pode crescer ainda mais de acordo com o tamanho da bateria do celular. A temperatura da bochecha e da orelha teve seu valor máximo quando o telefone móvel estava em contato com estas partes do corpo, e no caso em que ele estava carregando e sendo usado, ao mesmo tempo, em uma ligação. Alguns resultados mostraram, também, que as temperaturas dos aparelhos ultrapassaram o valor limite de 1°C, o que, segundo os pesquisadores, pode conduzir a problemas de saúde pelo fato de que o sistema homeotérmico não responde bem a acréscimos além deste valor. Sendo assim, para reduzir o aumento da temperatura da pele, sugeriram que o uso de celulares durante as ligações seja feito no modo de não-contato, com uso de fones auriculares, por exemplo.

Existe a necessidade de técnicas de rastreamento eficazes para que as pandemias de doenças infecciosas sejam prevenidas rapidamente. Através de termogramas do pescoço e do rosto, Nguyen et al. (2010 apud LAHIRI et al., 2012) inferiram que além de sensível, a termografia é um método rápido e não necessita do contato com a pele do paciente para monitoramento da febre. A alta temperatura corporal é um dos sintomas mais comuns em diversas doenças, inclusive as infecciosas. Portanto, o método citado torna-se uma ferramenta poderosa para realização de uma triagem inicial de determinado grupo de pessoas (NG, 2005). Em 2009, Nishiura e Kamyia (apud LAHIRI et al., 2012), utilizaram a câmera termográfica para avaliação de passageiros no aeroporto internacional de Nauta, no Japão, durante a crise na saúde gerada pelo vírus Influenza A (H1N1). De forma semelhante, Furuichi et al. (2015)

indicaram a utilização deste mesmo equipamento no auxílio do controle prévio da chikungunya e da dengue.

Indivíduos com diabetes normalmente são hospitalizados devido a complicações (por exemplo, formação de úlceras) nas extremidades do corpo. As principais causas dessas complicações são a diminuição da irrigação sanguínea (doença vascular) e a perda de sensibilidade (neuropatia). Estes fatores acarretam em alterações na temperatura da superfície da pele e, por este motivo, a termografia torna-se uma excelente ferramenta para diagnóstico dessas disfunções. Hosaki et al. (2002 apud LAHIRI et al., 2012) investigaram a circulação periférica em um grupo de diabéticos por meio de imagens térmicas e observaram que gradientes de temperatura, indicando fluxo anormal nas regiões afetadas, estão correlacionados com achados clínicos. Por sua vez, Liu et al. (2013) integraram a câmera termográfica à rotina clínica para exames frequentes nos pés dos pacientes e desenvolveram uma ferramenta quantitativa para análise dos termogramas. Nesse caso, o uso da termografia possibilitou a identificação de riscos de úlceras ou outras complicações a partir do aumento/diminuição da temperatura nos membros avaliados.

Além de ser utilizada em estudos envolvendo indivíduos com coração transplantado (MANGINAS et al., 2010 apud LAHIRI et al., 2012), a termografia pode auxiliar também na detecção de sinais iniciais de aterosclerose e, assim, atuar como um indicador precoce de ataque cardíaco. Nas pesquisas de Santos, Branco e Brioschi, (2015) foi investigado o uso desta técnica na avaliação da função endotelial e a correlacionou com o risco de eventos cardiovasculares. Os resultados mostram que há uma forte correspondência entre os achados termográficos (por exemplo, hiperatividade simpática e temperatura máxima de isquemia) e o risco cardiovascular.

Segundo alguns pesquisadores, a termografia aplicada à ginecologia é um campo que possui diversas aplicações, principalmente pelo fato de que durante a gravidez a genitália feminina interna sofre mudanças significativas no tamanho, na vascularidade e no volume do útero, causando o consequente aumento nos vasos sanguíneos e na temperatura da área (BIRNBAUM & KLIOT, 1964 apud LAHIRI et al., 2012). Menczer e Eskin (1969 apud LAHIRI et al., 2012) estudaram as dores pós-parto nos mamilos, por exemplo, e foi relatado que pacientes com dores apresentam temperatura mais elevada quando comparada com aquelas sem dor pós-parto. Esta dor é causada, geralmente, pelo ingurgitamento venoso e linfático ou enchimento dos ácinos com leite. Estes processos causam o aumento da vascularização e da temperatura, o que torna a termografia eficaz para esta aplicação.

No planejamento da cirurgia plástica deve-se tomar conhecimento da anatomia da circulação dos tecidos que serão mobilizados. Para este fim, Nogueira, Nogueira e Ely (2015) propuseram a integração da termografia por infravermelho à rotina de realização de imagens para diagnóstico, prognóstico e/ou para seguimento de determinada especialidade. Os resultados obtidos sugerem que esta técnica possui atuação muito positiva nas cirurgias plásticas, demonstrando ser um método prático, rápido e eficaz que pôde minimizar os índices de perdas teciduais e melhorar a qualidade dos resultados cirúrgicos e pós-cirúrgicos (por exemplo, o acompanhamento de úlceras de pressão).

De forma geral, a termografia é de baixo custo, não invasiva, simples, indolor, segura (sem efeitos colaterais conhecidos), prática e não requer nenhum contato nem compressão e nenhuma radiação ou acesso venoso (TAN et al., 2007). Essa técnica permite detectar as respostas fisiológicas dos tecidos, fornecendo informações funcionais que são muitas vezes melhores avaliadas que as características anatômicas (WANG et al., 2010). A boa interpretação da imagem térmica é fundamental para o acerto do diagnóstico (QUEIROZ, 2014).

2.3 Sistemas CAD Aplicados às Imagens Térmicas de Mama

A detecção precoce do câncer de mama proporciona maiores chances de sobrevivência das pessoas assintomáticas e/ou sintomáticas. Segundo Diakides et al. (2006), médicos indicaram que a angiogênese, relacionada com o crescimento do tumor, pode ser detectada facilmente pela câmera termográfica de um a cinco anos antes de qualquer outro método. Já no estudo de Ng (2009), foi preconizado que a termografia pode ter o potencial de detectar o câncer mamário dez anos antes do que a mamografia.

Apesar destes relatos, existe ainda certa resistência da comunidade médica na utilização da termografia devido à baixa sensibilidade para detectar tumores pequenos e profundos, à impossibilidade de diferenciar tumores de pontos quentes correspondentes às inflamações locais e à subjetividade utilizada pelos médicos para interpretar o diagnóstico através dos termogramas (BORCHARTT, 2013). Como solução destes problemas, e como forma de proporcionar maior confiabilidade ao diagnóstico do câncer de mama, estão sendo desenvolvidos diversos sistemas de diagnóstico auxiliado por computador (CAD).

As técnicas básicas que compõem um sistema de CAD são: o processamento e o estudo da imagem para a detecção de anomalias, a extração de características da imagem

processada, a análise de dados para a classificação da imagem (por exemplo, anomalia benigna ou maligna) e a avaliação quantitativa do desempenho do teste de diagnóstico utilizando, por exemplo, a análise ROC (*Receiver Operating Characteristic*) (PINHO, 2015).

Normalmente, os sistemas de CAD, baseados em imagens, consideram a comparação entre as duas mamas. Em todos os tipos de exames utilizados para detectar alterações mamárias, espera-se encontrar determinada simetria entre as mamas. Então, evidências de assimetrias podem ser indicativas de doenças na mama ou alguma alteração nela. No caso das imagens termográficas, uma elevada diferença nos padrões de distribuição de temperatura entre as mamas sugerem um sinal de alerta (QUEIROZ, 2014).

Diversos estudos procuram identificar a possibilidade do uso de reconhecimento de padrões na classificação das imagens térmicas. Arora et al. (2008 apud RESMINI et al., 2012) analisaram um sistema de CAD térmico com três modelos de operação: triagem, clínico e rede neural artificial. Os autores não relataram sobre as características extraídas e nem como o *software* trabalha, mas expuseram as acurácias obtidas por cada modo: triagem, 66,70%; clínico, 71,40%; e rede neural artificial, 81,80%.

Schaefer, Závisek, Nakashima (2009) utilizaram uma amostra de 146 termogramas (29 casos malignos e 117 casos benignos) e trabalharam com 38 características, das quais 11 foram selecionadas após o uso de um filtro Laplaciano. O universo das características foi formado a partir de medidas estatísticas e de descritores de Fourier (medida de forma). Estas características foram analisadas através da lógica *fuzzy* com uma técnica de validação cruzada e os melhores resultados obtidos nesse estudo foram: 79,53% de acurácia, 79,86% de sensibilidade e 79,49% de especificidade.

No estudo de *softwares* que auxiliam no diagnóstico do câncer de mama, Acharya et al. (2010) utilizaram 50 imagens de infravermelho (25 de mamas normais e 25 de mamas com câncer) para detectar automaticamente anormalidades mamárias. O processo de segmentação ocorreu a partir de um retângulo que envolve toda mama, o que resulta na inclusão de áreas que não pertencem à região de interesse (ROI – *Region Of Interest*) podendo comprometer as demais análises. Foram extraídas 16 características de textura, embora que no decorrer do método somente quatro características foram empregadas por terem sido consideradas como clinicamente significantes comparadas com as outras. O método de classificação utilizada foi o *Support Vector Machine* (SVM) que mostrou um bom desempenho no reconhecimento de padrões de maior parte da amostra. Com esta técnica, os autores obtiveram 88,10% de acurácia, 85,71% de sensibilidade e 90,48% de especificidade.

Borchardt (2013) utilizou uma amostra composta por 69 imagens termográficas (19 de mamas saudáveis e 50 de mamas com patologias), sendo que 51 imagens foram obtidas no Hospital das Clínicas da Universidade Federal de Pernambuco (HC/UFPE) e 18 imagens foram obtidas no Hospital Universitário Antônio Pedro da Universidade Federal Fluminense (HUAP/UFF). É importante ressaltar que as imagens do HUAP/UFF que representam alterações foram classificadas segundo o seu BI-RADS: BIRADS-1 para as pacientes normais e BIRADS-2 para as pacientes anormais. Esta última metodologia é questionável, visto que a classe BIRADS-2 também indica ausência de risco de nódulo maligno (DOURADO NETO, 2014). Um pré-processamento foi realizado para corrigir a posição da paciente na imagem com intuito de melhorar os resultados da segmentação. Tal segmentação foi realizada automaticamente com auxílio do software desenvolvido por Marques (2012), porém, em alguns casos ela não foi satisfatória, sendo necessária uma segmentação manual.

No trabalho de Borchardt (2013) foram extraídas 40 características obtidas de medidas estatísticas simples, de dimensão fractal da região mamária e de medidas baseadas em geoestatística. A seleção das melhores características foi baseada no algoritmo genético. O classificador SVM foi utilizado para classificar a amostra em duas classes (normal e anormal) e o processo de validação da classificação foi realizado pela técnica *leave-one-out* e pela *17-fold*. Como resultados foram obtidos os seguintes valores: 88,2% para taxa de acerto, 91,9% para sensibilidade e 78,6% para especificidade. Porém, estes resultados simplesmente apontam para a existência de alguma anormalidade, das quais a maior parte é benigna, sendo o teste pouco informativo sobre o efetivo risco de câncer.

Araújo (2014) propôs um sistema para classificação de anomalias mamárias (tumor maligno, tumor benigno e cisto) usando imagens termográficas. O pré-processamento da imagem foi iniciado pela segmentação da região das mamas, a partir de elementos elipsoidais gerados de forma semiautomática ou manual por meio do Matlab[®]. Em seguida, um processo morfológico foi realizado sobre cada imagem obtida da segmentação, que incluiu a definição de um elemento estruturante e de processos de erosão, dilatação e *Top Hat*, para determinar a altura dos máximos locais de temperatura com relação à temperatura da sua vizinhança. A extração de características foi realizada sobre as imagens segmentadas e aquelas obtidas da morfologia. Para tal extração foram propostas duas abordagens: a primeira baseou-se na extração de variáveis contínuas obtidas de medidas de dissimilaridade intervalar e que, em seguida, foram transformadas em um novo espaço de características pelo critério de Fisher. Na segunda abordagem foram extraídas variáveis intervalares de temperatura referentes às

quatro matrizes de entrada. Foram usadas 50 pacientes e todos os classificadores usados (classificação por discriminação linear, classificação por distância mínima e por Janela de Parzen) foram validados usando a técnica *leave-one-out*. O resultado obtido na primeira metodologia foi de 84% para taxa de acerto da classificação; 85,7% para sensibilidade e 86,5% para especificidade da classe Maligno; e na segunda metodologia atingiu 84% de taxa de classificação correta com 93% de sensibilidade para a classe Maligno.

Dourado Neto (2014) desenvolveu um sistema de CAD baseado na segmentação automática da região das mamas. Para isto, a matriz de temperatura associada a cada imagem termográfica foi tratada em tons de cinza. A primeira etapa da segmentação foi a separação entre a região do corpo e do fundo da imagem, a partir do processo de limiarização. O próximo passo foi a eliminação das regiões do pescoço e axilas, pela definição do ponto mais acima onde se iniciam os braços. A parte inferior foi eliminada através da seleção de bordas que começa na região central, entre as duas mamas, e segue em descida para cada limite inferior das mamas, excluindo cada *pixel* e toda sua linha abaixo se este possui o valor máximo da linha vertical a qual o *pixel* pertence e se o *pixel* vizinho lateral mais central já foi excluído. A última etapa da segmentação foi a retirada de possíveis regiões laterais superiores residuais, com a definição de linhas retas que se iniciam nos pontos entre as mamas e as axilas e que formam um ângulo de 60° com a horizontal. Foram extraídas 20 características, dentre elas características intervalares e estatísticas, e a escolha das melhores foi realizada pelo *software* WEKA (*Waikato Environment for Knowledge Analysis*). Para as melhores características, o SVM foi o classificador mais adequado com os seguintes resultados: 89,36% de taxa de acerto, 87,50% de sensibilidade e 90,32% de especificidade.

Silva et al. (2015a) analisaram as imagens termográficas de mamas para identificar pacientes com risco de câncer. O teste foi realizado com 22 pacientes (11 casos malignos e 11 normais), com a obtenção de 20 imagens para cada uma delas. Após o registro destas imagens, foi obtida a formação do sinal térmico a partir da divisão da mama em regiões com tamanho de 3x3 *pixels*, do cálculo da temperatura média sobre cada região e da interpolação por convolução cúbica desses pontos. As características dos sinais térmicos foram calculadas através de medidas de complexidade e agrupadas automaticamente segundo seu grau de semelhança (clusterização). Os autores utilizaram técnicas de aprendizagem de máquina (rede neural, rede Bayesiana e árvore de decisão) para classificar os vetores de características e obtiveram uma variação percentual de taxa de acerto de 86,36 - 91,90%, considerando os resultados de todos os classificadores.

Em seus recentes estudos, Schaefer e Nakashima (2015) utilizaram algumas estratégias para tratar do desequilíbrio de classes (maior número de casos benignos que malignos) no contexto de classificar o câncer de mama em imagens por infravermelho. A extração de características ocorreu de forma similar ao trabalho anterior desses autores (SCHAEFER; ZÁVISEK; NAKASHIMA, 2009). A principal sugestão do trabalho foi o uso de Sistemas com Múltiplos Classificadores (MCSs – *Multiple Classifier Systems*) para melhorar o desempenho dos classificadores base. A primeira estratégia utilizada foi a realização da classificação *cost-sensitive* que incorpora diferentes fatores (ou funções) de custo na função de distribuição das classes, visando a obtenção de uma regra de decisão final que dá mais importância à classe maligna. A segunda estratégia foi a formação de um conjunto cujos classificadores base são treinados sobre subespaços equilibrados, definidos a partir de correlações, e analisados pela lógica *fuzzy*. Por fim, a terceira estratégia foi utilizar o classificador *on-class* sobre a amostra desbalanceada e tentar identificar objetos de uma classe específica, aprendendo a partir de um conjunto de treino que contém apenas os objetos dessa classe.

Todas as três estratégias foram avaliadas para um conjunto de 146 termogramas (29 casos malignos e 117 casos benignos) e mostraram um bom desempenho no processo de classificação. Para o classificador *cost-sensitive*, para o classificador com amostra equilibrada e para o classificador *on-class* foram obtidos os seguintes grupos de valores, respectivamente: 81,02% de sensibilidade, 92,35% de especificidade e 90,10% de acurácia; 81,28% de sensibilidade, 90,53% de especificidade e 90,43% de acurácia; e 82,13% de sensibilidade, 88,78% de especificidade e 87,46% de acurácia.

Síntese dos sistemas de CAD avaliados

A Tabela 2 apresenta uma síntese com as informações mais relevantes acerca dos sistemas de CAD avaliados neste tópico. Nesta tabela, Sens. e Esp. representam, respectivamente, a sensibilidade e a especificidade e 1ª, 2ª e 3ª representam as diferentes abordagens realizadas por alguns autores.

Tabela 2 – Sistemas de CAD analisados.

Pesquisador	Amostra	Ext. caract.	Classific.	Taxa (s) de Acerto (%)	Sens. (%)	Esp. (%)
Arora et al. (2008)	-	-	-	66,70; 71,40; 81,80	-	-
Schaefer, Závisek, Nakashima (2009)	146	Estatística e descritores de Fourier	Lógica fuzzy	79,53	79,86	79,49
Acharya et al. (2010)	50	Textura	SVM	88,10	85,71	90,48
Borchardt (2013)	69	Estatística e dimensão fractal e geoestatística	SVM	88,20	91,90	78,60
Dourado Neto (2014)	47	Estatística e intervalares	SVM	89,36	87,50	90,32
Araújo (2014)	50	Contínuas e intervalares	Discriminante linear Distância mínima Janela Parzen	1ª – 84,00 2ª – 84,00	1ª – 85,70 2ª – 93,00	1ª – 86,50 2ª – 86,00
Silva et al. (2015a)	22	Medidas de complexidade	Aprendizado de máquina	86,6 – 91,9	-	-
Schaefer, Nakashima (2015)	146	Estatística e descritores de Fourier	Múltiplos Classificadores	1ª – 90,10 2ª – 90,43 3ª – 87,46	1ª – 81,02 2ª – 81,28 3ª – 82,13	1ª – 92,35 2ª – 90,53 3ª – 88,78


2.4 Interfaces Gráficas Relacionadas e Não Relacionadas à Termografia

Uma interface gráfica de usuário (GUI- *Graphical User Interface*) é uma interface pictórica com um programa. Uma boa GUI pode tornar os programas mais fáceis de usar, ao fornecer para eles uma aparência consistente e com controles intuitivos. A GUI deve se comportar de maneira compreensível e previsível, para que o usuário saiba o que esperar ao executar uma ação (CHAPMAN, 2003).

Souza, Andreão e Segatto (2006) implementaram e integraram rotinas de análise de eletrocardiograma (ECG), em ambiente Matlab®, para o monitoramento da atividade elétrica do coração. A interface gráfica desenvolvida proporciona a visualização do sinal de ECG, assim como os resultados dos algoritmos de segmentação por abordagem estatística Markoviana das ondas elementares do batimento cardíaco (P, QRS, T e linha isoeletrica) e de

classificação dos eventos cardíacos (batimentos ventriculares prematuros e isquemia). No uso da interface deve-se, primeiramente, executar a operação de inicialização das variáveis do sistema indicando o caminho onde estão salvos os registros, a pasta onde serão salvos os resultados e a base de dados escolhidas. Em seguida, após a ação dos algoritmos citados, o usuário tem as seguintes opções de visualização dos resultados (Figura 2): sinal puro do ECG, sinal segmentado e sinal classificado. É possível, também, a exibição dos intervalos R-R e dos eventos de isquemia escolhendo-se o tamanho do bloco do sinal, de modo a facilitar a interpretação dos dados. Os autores concluíram que, apesar de não operar em tempo real, o aplicativo possibilitou a detecção de eventos importantes no monitoramento de pacientes com risco de infarto no miocárdio.

Figura 2 – Janelas da GUI com exemplos de visualização do sinal de ECG segmentado, do gráfico de desvio do segmento ST e dos intervalos R-R no tempo.




Fonte: SOUZA; ANDREÃO; SEGATTO, 2006.

Kapoor, Prasad e Patni (2012) criaram uma interface gráfica no Matlab[®] que inclui técnicas de segmentação automática da ROI e de análise de assimetria entre as mamas de imagens termográficas. Através desta interface, apresentada na Figura 3, o usuário pode escolher a imagem e selecionar a opção de pré-processamento da mesma, que consiste na remoção do fundo e no redimensionamento da imagem para remover partes do corpo indesejadas. Apertando o botão de segmentação, as áreas das mamas são segmentadas automaticamente através dos operadores Canny de detecção de bordas e gradiente. A análise da assimetria é feita no acionamento do botão que, inicialmente, extrai os parâmetros de alta

ordem estatística (HOS – *High Order Statistical*) e calcula o centro de gravidade de regiões da mama, e do botão de geração de histograma que possibilita a análise da distribuição de temperatura sobre cada ROI. A interface permite ainda a visualização da imagem escolhida, da imagem pós-processamento e da imagem segmentada. No geral, os resultados mostraram que o estudo da assimetria auxilia no diagnóstico médico de anormalidades mamárias e o uso da GUI permite uma abordagem mais eficaz e em tempo real, independente do sistema operacional. Porém, a desvantagem da análise realizada apenas por meio de uma segmentação é subjetividade e a baixa confiabilidade relacionada à ausência de um sistema de classificação, por exemplo.

Figura 3 – Detalhes da interface gráfica criada.



Fonte: KAPOOR; PRASAD; PATNI, 2012.

O estudo de Santos et al. (2007) foi motivado pela dificuldade na medição de temperaturas *in vivo* de pacientes submetidos à radiofrequência para tratamento de tumores de próstata. A principal ferramenta deste trabalho foi o *software* APID (Aquisição de Pontos em Imagem Digital), desenvolvido na plataforma Matlab®, que facilita a manipulação e extração dos pontos e domínios em imagens médicas bidimensionais. A interface desenvolvida para este programa possui quatro menus: Arquivo, Operações, Visualizar e Ajuda. O menu Arquivo (Figura 4) é o local onde é possível abrir e salvar imagens, além de permitir ao

usuário o dimensionamento da imagem para definir medidas reais do modelo. No menu Operações encontram-se ferramentas para manipulação da imagem, possibilitando a determinação dos domínios e dos segmentos em que ela será segmentada e a definição da condição de contorno do segmento. O menu Visualizar permite que o usuário verifique o resultado dos arquivos de saída, disponibilizados para serem abertos por qualquer editor de texto comercial. Finalmente, o menu Ajuda fornece ao usuário a opção de esclarecer dúvidas quanto ao funcionamento do programa, bem como a versão do aplicativo e as últimas atualizações.


Figura 4 – Tela principal (Menu Arquivo).



Fonte: SANTOS et al., 2007.

Para o sistema proposto por Acharya et al. (2010), descrito no tópico anterior, foi desenvolvida uma interface gráfica (Figura 5) na plataforma Matlab®. O botão *Load Image* permite que o usuário carregue a imagem termográfica na tela da própria interface e, logo em seguida, são apresentadas as imagens em tons de cinza resultantes da segmentação. No campo *Patient Information* contém as informações do paciente (nome, idade e gênero) correspondentes à imagem selecionada. Por fim, ao clicar o botão *Support Vector Machine* (SVM) as características da imagem são extraídas automaticamente, depois são utilizadas como entrada do classificador SVM e o resultado desse processo é exposto no campo *Result*. Na figura, observa-se que a classe final do termograma foi a “Maligna”.

Figura 5 – GUI do sistema proposto.



Fonte: ACHARYA et al., 2010.

Oselame, Neves e Sanches (2014) propuseram um método para a medição de lesões dermatológicas por meio da análise de imagens captadas por um *hardware* desenvolvido para este fim. Este método estabelece o uso da fotogrametria, cuja finalidade é obter medidas da forma e das dimensões dos corpos ou de parte deles por imagens digitais. Lesões benignas costumam ter tamanho inferior a 10 milímetros, enquanto que melanomas usualmente são maiores. Utilizando o Matlab[®], foi implementada uma interface gráfica para facilitar o uso da ferramenta computacional criada para medição da área de determinada lesão. Na interface é possível abrir a imagem desejada e, ao clicar no botão “Resultado em cm”, converter o perímetro calculado em *pixel* para centímetro. A Figura 6 representa o processo final realizado pelo *software* na GUI desenvolvida. Concluiu-se que a técnica proposta foi capaz de garantir precisão na medição dos diâmetros das lesões, podendo associá-los ao fator de risco para melanomas, com baixo custo de utilização.


Figura 6 – Interface gráfica Perímetro.



Fonte: OSELAME; NEVES; SANCHES, 2014.

Santos (2014) desenvolveu uma infraestrutura de software, nomeada de AVMTM (Avaliação de Modelos Térmicos de Mama), para análise de um modelo térmico da mama, a partir de ferramentas numéricas agrupadas numa interface gráfica. A interface criada (Figura 7) possui quatro menus: Arquivo, Operação, Análise e Ajuda. No menu Arquivo é possível abrir a imagem por infravermelho através do programa *QuickReport* e exportar a matriz de temperaturas como um arquivo .csv. No menu Operação, duas técnicas podem ser realizadas: mapeamento (frontal/ lateral) ou triangulação (interpolação) e ainda a operação “Pontos comuns” a qual encontra as temperaturas dos pontos em comum nos dois mapeamentos, salvando-os em um arquivo .txt. No menu Análise pode-se escolher dois modelos de tumor (esférico/ cilindro elíptico) e realizar simulações com várias posições, tipos de tumor e tamanhos. Por fim, o menu Ajuda proporciona ao usuário uma explicação sobre a interface e suas funcionalidades.

Figura 7 – Interface gráfica AVMTM (Menu Arquivo).



Fonte: SANTOS, 2014.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 Uso do Computador no Apoio ao Diagnóstico Médico

O diagnóstico auxiliado por computador (CAD – *Computer-Aided Diagnosis*) pode ser definido como um diagnóstico feito por profissionais que utilizam o resultado de análises quantitativas automatizadas de imagens digitais, para auxiliar na tomada de decisão a respeito de uma avaliação (MARQUES, 2001 apud FRONER, 2015). Aplicações com diversas finalidades têm sido desenvolvidas por vários grupos de profissionais, visando auxiliar na composição de diagnósticos como uma forma de contribuir para a detecção precoce de doenças.

Em geral, os sistemas de CAD fornecem opiniões a partir de informações prévias de especialistas e informações extraídas de imagens médicas. Normalmente, o computador é usado como ferramenta para obtenção de informação adicional, sendo o diagnóstico final realizado pelo médico especialista (MARQUES, 2001).


A finalidade do sistema de CAD é melhorar a acurácia do diagnóstico, bem como a interpretação da imagem digital, através da resposta do computador como referência (MARQUES, 2001). Esta resposta é útil, pois o diagnóstico médico pode ser influenciado por diversos fatores que levam ao surgimento de erros de interpretação, tais como: a baixa qualidade na imagem, a localização e o tamanho da lesão, a fadiga visual ou a distração, as questões ambientais (como a luz ambiente) e a falta de experiência do médico especialista (RODRIGUES, 2008 apud PORTO, 2010).

Basicamente, existem dois tipos de aplicações de sistemas de CAD: o CADe (*Computer-Aided Detection*) que auxilia na detecção de áreas suspeitas a partir da identificação de padrões anormais fazendo-se a varredura da imagem pelo computador. E o CADx (*Computer-Aided Diagnosis*) que ajuda no diagnóstico através da quantificação de características da imagem e sua classificação correspondendo a padrões normais ou anormais (MARQUES, 2001 apud FRONER, 2015; PORTO, 2010).

Em geral, estes sistemas utilizam técnicas provenientes da inteligência artificial que envolve métodos de processamento de imagem para realce, segmentação, extração e seleção de atributos e reconhecimento de padrões (CASTLEMAN, 1996 apud MAZZONCINI, 2001).

A Figura 8 apresenta um fluxograma dos sistemas de CADe e de CADx. Verifica-se que a saída dos sistemas de CADe corresponde à localização de uma lesão suspeita, enquanto que nos sistemas de CADx essa lesão será classificada como maligna ou benigna, por exemplo, e fornecerá uma estatística relacionada a essa indicação.

Figura 8 – Fluxograma de sistemas CADe e CADx.



Adaptada de NISHIKAWA, 2010 apud PINHO, 2015.

O uso de sistemas de CAD proporciona vários benefícios, dentre eles um maior aproveitamento do tempo para determinada investigação, a possibilidade de existir um segundo “observador” com menor custo, e a objetividade e a reprodutibilidade da medida dos atributos escolhidos (FRONER, 2015; PINHO, 2015).


3.1.1 Processamento da imagem termográfica

A imagem termográfica digital pode ser definida por uma função bidimensional $f(x,y)$ da intensidade luminosa associada a uma matriz de temperatura $T(x,y)$, onde x e y são coordenadas espaciais (planas) e cada elemento de $T(x,y)$ representa a temperatura do ponto (x,y) (GONZALEZ et al., 2004 apud ARAÚJO, 2014).

Esta imagem é representada por uma imagem indexada, ou *pseudo-color*, que possui duas componentes: uma matriz de temperatura e um mapa de cor. Portanto, o termograma é a representação de valores da matriz de temperatura como apontadores para o mapa de cor. Nesse caso as cores de cada *pixel* dependerão do mapa de cor aplicado e dos limites inferiores e superiores de temperatura definido pela escala do termograma, como se pode observar na Figura 9 (QUEIROZ, 2014).

Deste modo, como cada *pixel* representa o valor de temperatura definido pela matriz T , estes valores permanecem constantes independentemente da mudança do mapa de cor ou da escala de temperatura, viabilizando o tratamento das imagens a partir dos valores da temperatura ao invés da intensidade dos *pixels*.

Figura 9 – Imagens termográficas com limites diferentes de temperatura.



Fonte: QUEIROZ, 2014.

Segmentação

A segmentação de imagens consiste em identificar regiões homogêneas na imagem, separando aquelas que são significativas para determinada tarefa (DOUGHERTY, 2009 apud DOURADO NETO, 2014). O tipo de segmentação escolhido e a sua correta implementação

são fundamentais para o reconhecimento de padrões e influenciam no desempenho de métodos automáticos de decisão.

Várias técnicas de segmentação podem ser aplicadas às imagens médicas, contudo apresentam desempenhos diferentes, dependendo do tipo de imagem e da estrutura em análise. A técnica empregada pode segmentar microcalcificações, em mamografias, ou a região das mamas, em termografias (MULLER, 2007 apud QUEIROZ, 2014). Porém, a segmentação de termogramas torna-se difícil pela ausência de limites nítidos de temperatura em alguns locais e por suas estruturas disformes.

Para a extração da região de interesse, tanto a segmentação automática quanto a semiautomática podem ser utilizadas no suporte ao diagnóstico do câncer mamário. A segmentação automática, sem intervenção humana, em geral é mais rápida e proporciona uma maior objetividade na análise final. Normalmente, a opção pela segmentação semiautomática surge pela necessidade de reduzir os erros de segmentação que podem surgir na forma automática devido à assimetria natural entre as mamas e às variações anatômicas entre pessoas diferentes no corpo humano. Além disso, ela pode ser utilizada por um profissional de saúde para melhor definição da área de interesse (ARAÚJO, 2014; QUEIROZ, 2014).

Dessa forma, um processo de segmentação que identifique corretamente a região mamária de interesse é um requisito de fundamental importância para que as informações resultantes de análises estatísticas e/ou de simulações numéricas, baseadas em imagens termográficas, sejam confiáveis.

Extração de características

A extração de características pode ser definida como sendo a captura das informações mais relevantes para fazer uma classificação de um dado fornecido como entrada, ou ainda pode ser definida como um conjunto de informações necessárias para representar um objeto (DEVIJVER & KITTLER, 1982 apud CRUZ, 2008). Os tipos básicos de extração consideram uma ou mais das seguintes características das imagens: escala de cinza e de cores, valores de temperatura, textura, conjunto de pontos, contornos ou curvas, superfícies e regiões especificadas (OLIVEIRA, 2015).

A escolha das características apropriadas depende da imagem e do domínio do problema (DOUGHERTY, 2009). Porém, elas devem ser:

- Robustas: em relação à translação, à orientação, à escala e à iluminação;

- Invariantes: quanto à presença de ruídos e artefatos;
- Discriminantes: o intervalo de valores para objetos de classes diferentes devem ser distintos e com a menor sobreposição possível;
- Confiáveis: os objetos de uma classe devem ter valores semelhantes;
- Independentes: as características não devem ser correlatas para se evitar a redundância.

Para a detecção de uma doença ou um achado suspeito em um número considerável de pacientes, as características devem ser simples de extrair, requerer a mínima intervenção do usuário e contribuir significativamente para sensibilidade do sistema (DOUGHERTY, 2009).

As características $x_1, x_2, \dots, x_n$ de cada objeto são, normalmente, agrupadas em um vetor $\mathbf{x}$:

$$\mathbf{x} = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix}$$

onde n representa o número de características, e o conjunto desses vetores forma o espaço de características (DOUGHERTY, 2009).

A seleção de características, dentro do próprio conjunto de dados extraídos, é uma opção para identificar quais são as mais significativas para uma posterior classificação, permitindo descartar aquelas que não contribuem para a distinção dos objetos entre as classes. Uma redundância mínima possibilita uma redução do custo computacional e de armazenamento, uma diminuição do número de novas medições de dados, e o melhor entendimento dos dados e do modelo criado para descrever os objetos (WEBB & COPSEY, 2011 apud DOURADO NETO, 2014).

Atualmente, há uma constante geração e armazenamento de grande quantidade de dados. Apesar da evolução tecnológica dos processadores dos computadores, a tarefa de manipular estes conjuntos de dados ainda é um problema. Nesse contexto, surgiram os objetos simbólicos, também chamados de variáveis ou dados simbólicos, que tem como objetivo estender os métodos de análise de dados usuais (como por exemplo, métodos exploratórios e gráficos) para que possam tratar os dados mais complexos e de maior número (BOCK&DIDAY, 2000 apud SILVA, 2008).

As variáveis simbólicas podem ser expressas, considerando um único indivíduo, através de conjuntos de intervalos, de histogramas, de categorias, dentre outros. Os tipos de variáveis simbólicas mais comuns são: multivaloradas, intervalares e modais (SILVA, 2008). O presente trabalho utilizou classificadores baseados em objetos simbólicos de natureza intervalar.

Considerando que E seja um conjunto de objetos simbólicos, uma variável simbólica Y é considerada intervalar se $\forall k \in E$, o subconjunto $Y(k) = [a; b]$, onde $a \leq b$. Por exemplo, seja E um grupo de jovens e Y o tempo semanal para lazer (em horas), para os indivíduos $i, j \in E$ é possível ter: $Y(i) = [3; 5]$ e $Y(j) = [7; 9]$ (SILVA, 2008).

No estudo utilizando imagens termográficas, é possível definir um intervalo baseado nas temperaturas contidas em uma ROI como sendo $Y = [T_{\min}; T_{\max}]$, onde $T_{\min}$ e $T_{\max}$ são, nesta ordem, os limites inferior e superior do intervalo de temperatura. E representam a temperatura mínima e máxima da região de interesse, respectivamente (ARAÚJO, 2014).


3.1.2 Classificação

A classificação é, muitas vezes, a etapa final de um processo de diagnóstico auxiliado por computador. Trata-se da parte do processo em que são estabelecidos critérios que podem ser usados para distinguir e identificar as imagens em diferentes classes (RUSS, 2001 apud DOURADO NETO, 2014). As técnicas de classificação podem ser divididas em três áreas principais: estatística, estrutural e híbrida, que incluem as redes neurais e os algoritmos genéticos. As técnicas de classificação estatísticas são as mais populares, seguida das técnicas híbridas, que ganharam popularidade durante a última década (DOUGHERTY, 2009).

Na construção de um classificador é fundamental a definição de um grupo de treino, utilizado no processo de aprendizagem de máquina. Neste processo, o classificador “aprende” através da amostra de treinamento, gerando a regra de classificação que será aplicada nos casos futuros (ARAÚJO, 2014).

O aprendizado pode ser supervisionado ou não supervisionado. Ele é dito supervisionado quando as classes dos objetos do grupo de treino são conhecidas, e não supervisionado (*clustering*) quando as classes não são conhecidas e devem ser identificadas as mais adequadas (DOURADO, 2014).

Figura 10 – Aprendizado de máquina supervisionado.



Fonte: BORCHATT, 2013.

A Figura 10 mostra de forma genérica a etapa de aprendizado de um classificador supervisionado. A base de treino é formada por diversos registros (x_i, y_i) , onde x_i representa o vetor de características e y_i indica a classe que cada vetor pertence. Dos registros são extraídas as características que melhor se adequam ao tipo de classificador utilizado. A partir daí, o algoritmo de aprendizagem de máquina constrói uma função/modelo que contém uma descrição compacta e funcional dos dados fornecidos. Esta função/modelo é utilizada para classificar novos registros cujas classes não são previamente conhecidas (DOUGHERTY, 2009; BORCHATT, 2013).

A quantificação e a qualificação do modelo preditivo gerado pelo classificador são feitas por técnicas de avaliação como, por exemplo, a validação cruzada. Entre os métodos de validação cruzada existentes, os mais comuns são o *k-fold* e o *leave-one-out*. No método *k-fold* a amostra inicial de n indivíduos é dividida aleatoriamente em k subconjuntos, dos quais $k-1$ são usados para treinamento e um para teste. A rotina é repetida k vezes até que todos os subconjuntos sejam usados como grupo de teste (FERREIRA, 2007apud ARAÚJO, 2014; DOURADO NETO, 2014).

A técnica *leave-one-out* é computacionalmente custosa e é equivalente ao método de validação cruzada *k-fold*, onde $k = n$. Neste caso, um indivíduo serve de teste e $n-1$ são usados na construção da regra de classificação. O método é repetido n vezes até que todos os elementos do conjunto de dados sejam utilizados como teste, a partir de n conjuntos distintos de treino (ARAÚJO, 2014).

Sensibilidade e Especificidade

Nos exames realizados para se detectar uma doença há duas possibilidades de resultado: positivo e negativo. Quando o resultado é positivo, o indivíduo pode ter a doença (Verdadeiro Positivo) ou pode não tê-la (Falso Positivo). Da mesma forma, quando o resultado é negativo, o indivíduo pode não ter a doença (Verdadeiro Negativo) como pode tê-la (Falso Negativo).

A avaliação da performance de um classificador associado a um sistema de CAD é, normalmente, calculada através de índices de sensibilidade e especificidade para cada classe avaliada. Embora estas medidas estejam relacionadas com um teste de classificação binária, é possível generalizar este conceito para um problema com mais de duas classes.

A sensibilidade representa a proporção de indivíduos com o problema em questão que são identificados corretamente pelo sistema, ou seja, informa o quão bom é o sistema em identificar tal problema (QUEIROZ, 2014). Para a i -ésima classe, ela pode ser calculada como:

$$\text{Sensibilidade}_i = \frac{VP_i}{VP_i + FN_i} \quad (3.1)$$

onde VP_i são os resultados verdadeiros positivos para a classe i e FN_i são os falsos negativos referentes à classe i .

Já a especificidade é a proporção de pacientes sem o problema que são apontados corretamente pelo sistema, isto é, informa o quão bom é um sistema em identificar o indivíduo sem o problema em questão (QUEIROZ, 2014). Para a i -ésima classe tem-se:

$$\text{Especificidade}_i = \frac{VN_i}{VN_i + FP_i} \quad (3.2)$$

onde VN_i são os resultados verdadeiros negativos avaliados para a classe i e FP_i são os falsos positivos avaliados em função da classe i .

A sensibilidade de um método à classe maligno é um parâmetro importante na detecção do câncer mamário. Assim sendo, os sistemas de CAD, nos casos de dupla leitura, têm demonstrado capazes de reduzir as taxas de falsos negativos, quando é informado incorretamente que o paciente não tem a doença quando de fato tem (PINHO, 2015).

3.2 Interfaces Gráficas de Usuários – Plataforma Matlab®

O Matlab® (*MATrix LABoratory* – Laboratório de Matrizes) é um programa de computador de alto nível que permite a execução de operações de cálculo numérico a partir de matrizes; o desenvolvimento de algoritmos; a modelagem e a simulação de padrões; a análise de dados; a plotagem de gráficos científicos e de engenharia; e a elaboração de interfaces gráficas de usuário (GUI – *Graphical User Interface*).

Uma GUI torna os programas mais fáceis de usar por fornecer uma aparência consistente e com controles intuitivos. A aplicação e solução do programa associado a uma GUI devem ser realizadas de forma que o usuário saiba o que esperar ao executar qualquer ação relacionada ao algoritmo (CHAPMAN, 2003).

O ambiente da GUI contém botões, listas, menus e caixas de texto que são familiares ao usuário. Dessa forma, ele pode se concentrar na utilização do aplicativo sem se preocupar com a parte mecânica envolvida no desenvolvimento do programa propriamente dito. É o programador que assume este papel mais difícil, principalmente pelo fato de que um programa baseado em GUI precisa ser preparado para os botões do mouse ou para alguma entrada pelo teclado, para qualquer elemento da GUI e em qualquer momento.


Há três elementos fundamentais para a elaboração de uma GUI na plataforma Matlab®, são eles (CHAPMAN, 2003):

- Componentes: dentre os componentes gráficos de uma GUI tem-se controle gráficos (botões, caixas de edição, listas, etc.) que são criados pela função *uicontrol*; elementos estáticos (quadros e cadeias de caracteres de texto) que também são criados pela função *uicontrol*; menus que são criados pelas funções *uimenu* e *uicontextmenu*; e eixos, utilizados para exibir gráficos, que são criados pela função *axes*.
- Figuras: os componentes de uma GUI são organizados dentro de uma figura que é uma janela na tela do computador. As figuras vazias podem ser criadas através da função *figure* e usadas com qualquer combinação de componentes.
- Chamadas de retorno: são executadas pelo código quando se pressiona o botão de um mouse ou se digita informação pelo teclado. É necessário implementar uma chamada de retorno para cada componente gráfico de uma GUI.

As interfaces gráficas do Matlab[®] são criadas através da função *guide* (*Development Environment* - Ambiente de Desenvolvimento de GUI). Nesta ferramenta é possível projetar a GUI, selecionando e alinhando os componentes inseridos na mesma. Quando eles estão em suas posições, o programador pode alterar seus nomes, cores, tamanhos, fontes e outras propriedades. Ao gravar a GUI, o *guide* gera um programa funcionando que inclui funções de esqueleto que podem ser modificadas para implementar o código que define o comportamento da interface (CHAPMAN, 2003).

As etapas básicas para criação de uma GUI Matlab[®] são (CHAPMAN, 2003):

- Preparar um esboço da GUI, indicando quais elementos serão necessários e qual a função de cada um;
- Utilizar a Função *Guide* para inserir os componentes gráficos em uma figura (Figura 11). O tamanho da figura, o alinhamento e o espaçamento dos componentes presentes nela podem ser ajustados com as ferramentas disponíveis no *guide*;
- Utilizar a ferramenta *Inspetor de Propriedades* contida no *Guide*, para nomear e ajustar as características (tais como cor, texto exibido, e fonte) dos componentes;
- Gravar a figura em um arquivo. Quando esta ação é realizada, dois arquivos são gerados no disco com o mesmo nome, mas com extensões diferentes. O arquivo de extensão *fig* contém a GUI criada, e o arquivo *m* contém o código com os esqueletos de chamadas de retorno para cada elemento da interface;
- Escrever o código que dará funcionalidade a cada componente inserido na GUI.

Figura 11 – Janela de ferramentas *guide*.

O programa resultante é executado pela digitação do nome atribuído a ele na Janela de Comandos do Matlab[®]. Ao fazer isso, a interface é gerada automaticamente e fica disponível para o usuário realizar a ação desejada.

4 METODOLOGIA

O presente projeto tem como foco a criação de uma ferramenta computacional de CAD para análise de imagens termográficas de mamas que seja fácil de usar, e que forneça aos profissionais de saúde um suporte adicional para o diagnóstico do câncer mamário.

Para o desenvolvimento desta ferramenta foram utilizados sistemas de CAD criados por Araújo (2014) e Dourado Neto (2014). Mediante a inclusão da classe Normal ao classificador proposto por Araújo (2014), o desempenho desses sistemas foi avaliado para uma base dados com um número maior de pacientes com diagnóstico concluído.

A fim de se obter melhores resultados no processo de classificação utilizando o método SVM, também utilizado por Dourado Neto (2014), foram extraídas novas características baseadas naquelas propostas por este autor. O *software* WEKA foi utilizado para a seleção dos atributos mais adequados ao presente trabalho.

A técnica *one-versus-all* foi implementada ao classificador binário SVM para possibilitar uma análise de multiclases, fornecendo uma resposta mais adequada das taxas de acerto e permitindo uma melhor comparação com o método de classificação baseado na distância de Mahalanobis (ARAÚJO, 2014).


Para que os sistemas de CAD fossem implementados adequadamente à interface gráfica aqui desenvolvida foram necessários alguns ajustes:

- A segmentação automática (DOURADO NETO, 2014) foi adaptada para que seja escolhida a imagem da paciente que será avaliada individualmente;
- A amostra e os parâmetros relacionados a ela foram fixados a fim de serem usados no novo processo de classificação.

Por fim, a GUI foi criada na plataforma Matlab[®]. A mesma apresenta um painel, no qual há opções que possibilitam uma análise estatística dos dados que serão obtidos na avaliação da cada paciente, em um determinado período.

A Figura 12 exhibe de forma resumida a metodologia usada no desenvolvimento desta dissertação e tal metodologia será detalhada neste capítulo.

Figura 12 – Diagrama simplificado da metodologia adotada.



4.1 Aquisição e Armazenamento de Termogramas

As imagens termográficas utilizadas neste trabalho foram obtidas com uma câmera de infravermelho FLIR S45. Essas imagens são de pacientes do Ambulatório de Mastologia do Hospital das Clínicas (HC) da UFPE e a amostra selecionada é composta por mulheres com diagnóstico concluído através de exames clínicos tradicionais, ultrassonografia, mamografia e biópsia. Cada uma destas mulheres concordou em participar da pesquisa por meio da assinatura do Termo de Consentimento Livre e Esclarecido (TCLE), documento associado ao cadastro do projeto no Ministério de Saúde, sob o Registro CEP/CCS/UFPE N° 279/05 e aprovado pelo Comitê de Ética da UFPE.

A fim de se reduzir alguns erros gerados por oscilações de temperatura no interior da sala de exames ou da temperatura da paciente durante a aquisição das imagens, utilizou-se o protocolo para o exame termográfico estabelecido por Oliveira (2012).

De forma geral, para padronizar a aquisição das imagens foi desenvolvido um aparato mecânico que auxilia, principalmente, no posicionamento dos braços da paciente. Ele é formado por dois trilhos de deslocamento que servem de suporte para um pequeno carro, sobre o qual é posicionada a câmera termográfica juntamente com seu tripé. Conforme pode ser observado na Figura 13, há uma cadeira giratória na qual foram acopladas barras e, a barra de madeira é ajustável à altura da paciente visto que ela servirá de apoio para as mãos da paciente durante a aquisição de algumas imagens.

Figura 13 – Aparato mecânico.



Fonte: OLIVEIRA, 2012.

Antes da aquisição das imagens, espera-se cerca de dez minutos para que a temperatura da paciente se estabilize no ambiente. Além disso, as pessoas que auxiliam no exame, também, estão em equilíbrio térmico por se encontrarem na sala antes do início da aquisição (QUEIROZ, 2014).

Alguns dados são registrados por servirem como parâmetros de entrada para a câmera termográfica, são eles: a umidade relativa e a temperatura da sala, as distâncias entre a paciente e a câmera, e a emissividade da pele humana que foi considerada como sendo 0,98 (LAHIRI et al., 2012).

O armazenamento das imagens termográficas, das informações colhidas durante o registro médico das pacientes e das informações de outros exames é realizado em um banco de dados (IP: 150.161.49.5/projetoBD) que permite o acesso dos médicos e pesquisadores cadastrados através de um computador ligado na internet. Ele foi desenvolvido, sobretudo, para facilitar o acompanhamento dos profissionais envolvidos na investigação e para dar suporte ao processo de apoio à decisão.

4.2 Base de Dados

A amostra utilizada neste trabalho é composta, inicialmente, por 114 imagens termográficas de mamas que foram obtidas entre os anos 2005 e 2014 no HC/UFPE sob as condições citadas anteriormente.

Desta base de dados, 43 pacientes foram diagnosticadas com tumor benigno, 27 com tumor maligno, 24 com cisto e 20 pacientes não apresentaram anormalidades. O desbalanceamento da amostra em relação à quantidade de pacientes com tumores benignos pode interferir no processo de classificação, fazendo com que ele seja mais tendencioso para a classe Benigno. Por este motivo, 16 imagens foram retiradas aleatoriamente deste grupo, levando em consideração, também, o fato de que essas imagens apresentaram problemas na extração de características: exibiram valores nulos nas características referentes aos máximos entre as temperaturas máximas da matriz morfológica, obtida no processo de segmentação semiautomática, da mama direita e da mama esquerda.

Assim, a amostra que compôs a base de dados utilizada no desenvolvimento do presente trabalho corresponde a um total de 98 pacientes, e está resumida na Tabela 2 a seguir.

Tabela 3 – Base de dados de imagens termográficas.

Diagnóstico	Quantitativo
Normal	20
Tumor benigno	27
Tumor maligno	27
Cisto	24
Total:	98

As imagens por infravermelho têm formato *.jpeg*. Para a obtenção das matrizes de temperatura a partir das imagens termográficas, foi usado o *software* FLIR QuickReport que é disponibilizado pelo fornecedor da câmera. Neste programa, mesmo depois da aquisição das imagens e/ou quando for necessário, o usuário pode fazer ajustes no valor da emissividade, da temperatura refletida, da temperatura e da umidade relativa do ambiente e da distância entre a câmera e o objeto.


É possível exportar os valores de temperatura dos *pixels* para o programa Excel da Microsoft. As planilhas são salvas no formato *.csv*, após trocar as vírgulas do números decimais por pontos. As matrizes obtidas tem dimensão de 320×240 e são processadas como uma imagem térmica digital.

4.3 Segmentação

A segmentação da região de interesse (ROI) das imagens que compõem a base de dados foi realizada de duas formas: automática, desenvolvida por Dourado Neto (2014), e semiautomática, desenvolvida por Araújo (2014).

A matriz de temperaturas T da imagem termográfica é reconstruída como uma imagem digital através do Matlab[®], atribuindo uma cor a cada valor de temperatura, e sobre essa imagem é feita a segmentação. No caso da segmentação automática, a imagem foi tratada em tons de cinza, na qual os tons mais claros indicam as temperaturas mais altas, e o processo de extração da região de interesse ocorre sem nenhuma intervenção humana. A Figura 14 apresenta a imagem da paciente e o resultado desta segmentação.

Figura 14 – Resultado da segmentação automática.




Fonte: DOURADO NETO, 2014.

Na segmentação semiautomática é necessário que o usuário selecione cada mama a partir de elipses geradas manualmente no Matlab[®]. Ao final do processo, são obtidas duas matrizes de temperaturas independentes, uma referente à mama esquerda e a outra à mama direita (Figura 15).

Para a amostra utilizada pelos autores citados, as segmentações elaboradas foram consideradas confiáveis e efetivas para o projeto desenvolvido por cada um deles.

Figura 15 – Resultado da segmentação semiautomática.




Fonte: ARAÚJO, 2014.

4.4 Extração de Características

Após a definição das ROIs por meio das segmentações mencionadas anteriormente, tais regiões foram analisadas com o intuito de se extraírem características baseadas em informações de temperatura.

Dourado Neto (2014) utilizou abordagens fundamentadas em medidas estatísticas (como média, desvio padrão e análise de histogramas) e em medidas intervalares. No total foram extraídas vinte características e a seleção do melhor subconjunto foi realizada através do *software* livre WEKA. A combinação das características c_5 e c_6 , descritas abaixo, melhor separou a classe Maligno das demais classes (Figura 16).

Figura 16 – Representação de algumas características definidas a partir das temperaturas máximas e mínimas da mama esquerda e da mama direita.



Adaptada de DOURADO NETO, 2014.

onde:

c_1 = máximo entre as temperaturas máximas da mama esquerda e da mama direita;

c_2 = mínimo entre as temperaturas máximas da mama esquerda e da mama direita;

c_3 = máximo entre as temperaturas mínimas da mama esquerda e da mama direita;

c_4 = mínimo entre as temperaturas mínimas da mama esquerda e da mama direita;

$c_5 = c_1 - c_2$;

$c_6 = c_2 - c_3$.

Araújo (2014), em uma das suas abordagens, extraiu características intervalares das matrizes obtidas da segmentação e do processo morfológico realizado sobre elas. O intervalo formado pelas variáveis simbólicas intervalares foi separado em componentes de centro e de raio, gerando dois novos vetores contínuos. Resumidamente, dada uma observação intervalar $y = [a; b]$, o centro e o raio são valores escalares calculados através das equações abaixo.

$$centro = \frac{a+b}{2} \quad (4.1)$$

$$raio = \frac{a-b}{2}, raio \geq 0 \quad (4.2)$$

Estes vetores foram transformados em um novo espaço bidimensional de características a partir do critério de Fisher. A intenção desta transformação foi projetar as classes individuais em um novo espaço de características, no qual as classes fossem mais facilmente separadas (WEBB, 2002 apud ARAÚJO, 2014).

Ao fim são obtidos dois vetores: x_c , para o centro, e x_r , para o raio. Estes vetores foram reacoplados e foi obtido um vetor intervalar $\hat{v}$ da seguinte forma:

$$\dot{\mathbf{v}} = (x_c - x_r, x_c + x_r) \quad (4.3)$$

As características citadas acima foram as selecionadas para o desenvolvimento computacional da interface gráfica. Cada extração de característica foi associada à segmentação desenvolvida por seu respectivo autor.

4.5 Classificação

Após a devida extração de características, as variáveis selecionadas serviram de entrada para os classificadores utilizados. O objetivo inicial foi avaliar o desempenho dos classificadores quanto à classificação correta da presença de anormalidades (tumor benigno, tumor maligno e cisto) ou não, das pacientes que compõem a atual base de dados. A metodologia desenvolvida nesta dissertação adaptou os classificadores para serem utilizados na avaliação individual de pacientes cujos diagnósticos ainda não foram concluídos, o que não foi feito anteriormente pelos dois autores citados.

Para os dados extraídos através do processo desenvolvido por Dourado Neto (2014), o classificador que apresentou desempenho mais coerente em seu estudo foi o SVM com núcleo polinomial 5. A classificação foi feita para quatro classes (Benigno, Maligno, Cisto e Normal) distintas e os resultados obtidos para o número total de imagens utilizadas pelo autor foram: 79,49% de taxa de acerto, 67,44% de sensibilidade e 82,20% e especificidade.

O SVM consiste em uma técnica computacional de aprendizagem de máquina que é capaz de resolver problemas de classificação e de regressão, adquirindo a habilidade de generalização, com o aprendizado na etapa de treinamento. A essência do SVM é a construção de um hiperplano ótimo, de modo que ele possa separar diferentes classes de dados com elevada margem possível. A margem de um classificador é definida como a menor distância entre as variáveis do conjunto de treinamento e o hiperplano usado na separação desses dados em classes (LORENA & CARVALHO, 2007; BORCHARTT, 2013).

Os problemas não-lineares são tratados pelo mapeamento do conjunto de treinamento de seu espaço original X para um novo espaço de características de maior dimensão C . Este novo espaço possui alta probabilidade dos dados serem separados linearmente (LORENA & CARVALHO, 2007).

Para encontrar a superfície de decisão ótima, o algoritmo de treinamento do SVM tenta separar da melhor forma possível os pontos relacionados aos dados das classes

analisadas. Os pontos mais próximos do limite entre as diferentes classes são selecionados, por serem mais significativos na solução do que os pontos mais distantes e por ajudar a definir a forma da melhor superfície de decisão (LORENA & CARVALHO, 2007).

Alguns casos não conseguem gerar um bom hiperplano para ser usado como critério de separação. Para suprir esta dificuldade, utilizam funções *Kernel* ou núcleo. Estas funções são menos custosas que outros métodos e permite estender as aplicações sobre praticamente qualquer estrutura de dados.

De forma geral, um *Kernel* K é uma função que recebe, por exemplo, dois pontos x_i e x_j do espaço de entradas e computa o produto escalar (Equação 4.4) desses dados no espaço de características, a partir de uma função φ de mapeamento. Esta função possibilita a construção de máquinas de aprendizagem com diferentes tipos de superfícies de decisão não-linear no espaço de entrada (BORCHARTT, 2013).

Das funções *Kernel* existentes, foi utilizada neste trabalho uma função de núcleo polinomial de ordem 7 que pode ser definida pela Equação 4.5 abaixo (BORCHARTT, 2013). A escolha da ordem do polinômio foi baseada nos resultados obtidos por Dourado Neto (2015 - Comunicação Pessoal) e nos testes realizados no presente trabalho.

$$K(x, y) = \langle \varphi(x), \varphi(y) \rangle \quad (4.4)$$

$$K(x, y) = (r + \gamma x_i^T x_j)^d \quad (4.5)$$

onde, γ e d são parâmetros ajustáveis, e o índice T representa a matriz/vetor transposto.

Para as características extraídas através do método criado por Araújo (2014), foi utilizado um classificador de medidas de dissimilaridades baseado na distância mínima que usou como função de proximidade uma variação da distância de Mahalanobis baseada em intervalos. A classificação foi realizada para três classes diferentes (Benigno, Maligno e Cisto) e os resultados obtidos foram: 84% de taxa de acerto, sensibilidade de 93% para a classe Maligno e especificidade de 86% para a mesma classe.

Considerando um grupo Γ de m objetos simbólicos descritos por p variáveis intervalares, cada objeto $\mathbf{y}_i$ ($i = 1, \dots, m$) pertencente ao grupo foi representado por um vetor de intervalos $\mathbf{y}_i = ([a_{i1}, b_{i1}], \dots, [a_{ip}, b_{ip}])^T$. Seja P uma partição de Γ em Q classes $C_1, \dots, C_Q$, onde cada classe C_q ($q = 1, \dots, Q$) contém um protótipo L_q que também foi

representado com um vetor intervalar $\mathbf{g}_q = ([\alpha_{q1}, \beta_{q1}], \dots, [\alpha_{qp}, \beta_{qp}])^T$, onde $\mathbf{g}_q$ equivale às médias dos intervalos C_q (ARAÚJO, 2014). Para $j = 1, \dots, p$ tem-se:

$$\left[\alpha_{qj} = \frac{\sum_{i \in C_q} a_{ij}}{n_q}, \beta_{qj} = \frac{\sum_{i \in C_q} b_{ij}}{n_q} \right] \quad (4.6)$$

onde n_q representa o número de elementos na classe C_q .

O classificador de distância mínima atribui um objeto $\mathbf{v}_i$ à classe C_q se $d^\lambda(\mathbf{v}_i, \mathbf{g}_q) \leq d^\lambda(\mathbf{v}_i, \mathbf{g}_r) \forall r, r = 1, \dots, Q$. Neste caso, a função $d^\lambda(\mathbf{v}_i, \mathbf{g}_q)$ corresponde a uma distância de Mahalanobis parametrizada para intervalos.

A distância de Mahalanobis $\delta(\mathbf{v}_i, \mathbf{g}_q)$ entre duas observações intervalares $\mathbf{v}_i$ e $\mathbf{g}_q$ é definida como (SOUZA et al., 2004 apud ARAÚJO, 2014):

$$\delta(\mathbf{v}_i, \mathbf{g}_q) = d(\mathbf{v}_{il}, \mathbf{g}_{ql}) + d(\mathbf{v}_{is}, \mathbf{g}_{qs}) \quad (4.7)$$

onde: $d(\mathbf{v}_{il}, \mathbf{g}_{ql}) = (\mathbf{v}_{il} - \mathbf{g}_{ql})^T \mathbf{S}_l (\mathbf{v}_{il} - \mathbf{g}_{ql})$ representa a distância de Mahalanobis entre os vetores Inf (composto pelos limites inferiores das variáveis intervalares), $\mathbf{v}_{il}$ e $\mathbf{g}_{ql}$; e $\mathbf{S}_l$ é a matriz de covariância para os valores de Inf.

Analogamente, $d(\mathbf{v}_{is}, \mathbf{g}_{qs}) = (\mathbf{v}_{is} - \mathbf{g}_{qs})^T \mathbf{S}_s (\mathbf{v}_{is} - \mathbf{g}_{qs})$ representa a distância de Mahalanobis entre os vetores Sup (composto pelos limites superiores das variáveis intervalares), $\mathbf{v}_{is}$ e $\mathbf{g}_{qs}$; e $\mathbf{S}_s$ é a matriz de covariância para os valores de Sup (ARAÚJO, 2014).

A distância de Mahalanobis parametrizada pode ser definida por uma matriz de covariâncias comum entre Inf e Sup, parametrizada para cada classe. Assim, considerando $\lambda_q \in [0,1], (q = 1, \dots, Q)$ é um parâmetro de controle para a classe C_q , uma distância Mahalanobis parametrizada entre dois vetores intervalares pode ser definida como:

$$d^\lambda(\mathbf{v}_i, \mathbf{g}_q) = (\mathbf{v}_{il} - \mathbf{g}_{ql})^T \mathbf{S}_q (\mathbf{v}_{il} - \mathbf{g}_{ql}) + (\mathbf{v}_{is} - \mathbf{g}_{qs})^T \mathbf{S}_q (\mathbf{v}_{is} - \mathbf{g}_{qs}) \quad (4.8)$$

onde $\mathbf{S}_q(\lambda_q) (q = 1, \dots, Q)$ representa a matriz de covariâncias parametrizada. O parâmetro λ_q mede o grau de relevância entre os limites dos intervalos, Inf e Sup, no cálculo da matriz de covariâncias parametrizada da classe (ARAÚJO, 2014).

Da mesma forma que o autor citado, o valor de cada parâmetro λ_i foi variado de 0 até 1, com incrementos de 0,1 por meio de iterações sucessivas, verificando-se as possíveis combinações dos quatro parâmetros testados. O intuito foi encontrar para a base de dados

analisada, os melhores valores destes parâmetros a partir de condições que representam uma boa taxa de acertos combinada com o maior índice de sensibilidade para as quatro classes, principalmente a classe Maligno.

No presente trabalho, ambos os métodos utilizados para a classificação das características selecionadas foram validados pelo critério *leave-one-out*, onde 97 pacientes foram usadas como treino e uma paciente foi usada como teste. Esta avaliação é repetida para as 98 pacientes, de forma que 98 grupos diferentes são usados como treino e 98 elementos diferentes são utilizados como teste.

O desempenho das classificações foi calculado através da taxa de acerto de cada classificador e dos índices de sensibilidade e especificidade, para classe Maligno. Além disso, compararam-se entre si os resultados obtidos para cada método, verificando qual deles fornece uma análise mais rápida e mais precisa.

4.6 Ajustes dos Métodos de Análise

O objetivo final deste trabalho é adequar os métodos de segmentação e classificação desenvolvidos pelos autores referidos anteriormente, à criação de uma interface gráfica de uso médico para triagem de pacientes submetidas ao exame termográfico de mamas.

A segmentação automática criada por Dourado Neto (2014) ocorre de maneira que o usuário não escolhe uma única imagem de determinada paciente, mas há uma leitura e segmentação automática de todo grupo de imagens, que se encontram no formato de matriz de temperaturas, e que foi inserido previamente em um diretório.

O código da segmentação automática foi ajustado para que o operador seja capaz de escolher a imagem da paciente, que se deseja segmentar no momento da consulta ou de uma análise posterior. Assim, a imagem não necessita estar em um diretório específico, facilitando o processo de armazenamento.

Os processos de classificação utilizados foram desenvolvidos para analisar a eficiência de cada classificador no estudo da amostra específica. Para os fins desta dissertação, foi necessário ajustar cada classificador para que a mesma paciente que foi selecionada na segmentação pudesse ser avaliada individualmente quanto à presença ou não de anormalidades mamárias.

O classificador baseado na distância de Mahalanobis foi adaptado com a inclusão da classe Normal, que não foi considerada no desenvolvimento do trabalho de Araújo (2014) pela baixa quantidade de diagnóstico concluído de pacientes que compõem esta classe.

Para ambos classificadores, SVM e Mahalanobis, foram definidos três grupos diferentes: grupo de treino, grupo de validação e de teste, baseados na amostra que compõe a nova base de dados. O grupo de treino, formado pelas características das imagens termográficas da base, foi utilizado para aprendizagem do algoritmo. O grupo de validação, formado pelas classes de cada paciente, foi usado para verificar a generalização do algoritmo, a fim de ajustar os parâmetros de classificação. Após o processo de aprendizagem do programa, o grupo de teste foi utilizado para avaliar se os parâmetros definidos funcionam bem para qualquer amostra.

A partir deste ponto, foram analisadas as taxas de acerto, as sensibilidades e as especificidades dos classificadores para cada classe (normal, tumor maligno, tumor benigno e cisto). O intuito é verificar a eficiência dos classificadores e, a partir dos melhores resultados, fixar os parâmetros e as características extraídas da base de treino. Fazendo isto, cada paciente nova que se queira avaliar, será usada como “teste” e o resultado da classificação é gerado apenas para ela.

No classificador SVM foi fixado o grupo de treino relacionado às características c_5 e c_6 , descritas no Tópico 4.4. De forma semelhante, no classificador Mahalanobis foram fixadas as características intervalares, também descritas no Tópico 4.4, além dos parâmetros de controle de cada classe.

5 RESULTADOS E DISCUSSÃO

Neste capítulo é apresentada a interface gráfica desenvolvida e sua aplicação no estudo de cinco pacientes independentes:

- Paciente 1: que foi diagnosticada como portadora de mama normal;
- Paciente 2: que apresenta um tumor benigno;
- Paciente 3: que apresenta um cisto;
- Paciente 4 e Paciente 5: que apresentam um tumor maligno.

Os resultados foram obtidos com o uso dos sistemas de CAD, desenvolvidos por Araújo (2014) e Dourado Neto (2014), sobre as imagens termográficas que compõem a base de dados do sistema. Como discutido no Capítulo 4, diversas posições da paciente foram usadas para a captura de imagens termográficas. Aquelas que foram usadas neste trabalho são do tipo frontal com as mãos levantadas e apoiadas na barra de madeira do aparato mecânico.

Em seguida, expõe-se a tela que é aberta ao selecionar o menu **Help**. Além de se exibir um exemplo ilustrativo das funcionalidades que compõem o painel **Estatística**.

Os testes foram realizados em um computador com sistema operacional Windows 10, processador Intel Core i3 – 3217U (1,80 GHz), 4 GB de memória RAM e Sistema Operacional de 64 bits.

5.1 Interface Gráfica


Até o momento, os sistemas de CAD desenvolvidos e adaptados foram associados a uma interface gráfica de usuário (GUI), criada na plataforma Matlab[®]. Além de tornar o processo e obtenção de resultados mais automatizado, o uso da interface permite que o operador utilize diversas técnicas sem o conhecimento prévio da programação da ferramenta computacional. A Figura 17 mostra a GUI desenvolvida na presente dissertação. Ela possui dois menus (**File** e **Help**) e quatro painéis (**Informações do Paciente**, **Segmentação**, **Resultado** e **Estatística**).

Figura 17 – Interface gráfica Analise IR_MAMA.




No menu **File** o usuário tem a opção de abrir a imagem termográfica através do programa FLIR QuickReport e exportar a matriz de temperaturas no formato .csv, ou sair da interface. No menu **Help** encontra-se uma breve explicação sobre a interface e suas funcionalidades, com o intuito de que o usuário possa tirar suas dúvidas acerca da mesma (Figura 18).

Figura 18 – Menu File/Help.



No painel **Informações do Paciente** (Figura 19), o médico/pesquisador pode inserir os dados do paciente, tais como o número do prontuário, a idade e o gênero (masculino/feminino). Estes dados serão armazenados em um arquivo .txt para que eles possam ser usados posteriormente no painel Estatística.

Figura 19 – Painel Informações do Paciente.



Informações do Paciente


Número do Prontuário

Data da Análise

Idade Gênero

No painel **Segmentação** (Figura 20) é possível escolher entre dois tipos de segmentação das mamas (semiautomática ou automática), que estão associadas internamente aos classificadores relacionados para cada uma das segmentações.

Figura 20 – Painel Segmentação.




Segmentação

☐ Segmentação Semiautomática

☒ Segmentação Automática

O painel **Estatística** (Figura 21) serve para análises estatísticas dos dados registrados em determinado período. Por exemplo, caso se deseje saber a quantidade de casos clínicos (pacientes normais, com tumores malignos, com tumores benignos ou com cisto) no ano de 2015, no campo **Período** coloca-se 2015 2015 e ao selecionar **Casos Clínicos** aparecerá um gráfico “pizza” com os resultados. De forma semelhante, caso se deseje saber a distribuição dos casos clínicos por idade, ao selecionar **Casos clínicos × Idade** aparecerão histogramas referentes a cada classe.

Figura 21 – Painel Estatística.



Estatística

Período

☐ Casos clínicos

☒ Casos clínicos X Idade

A fim de padronizar e uniformizar os resultados obtidos, foi definido um novo índice THS (*Thermal Statistical Index*) baseado nas imagens termográficas e nos classificadores estatísticos, para indicar a existência de possíveis patologias mamárias. A proposta de tal

índice é ser similar ao BI-RADS que é usado nos exames de mamografia e ultrassonografia. A Tabela 3 mostra os valores atribuídos do THS e suas respectivas definições.

Tabela 4 – Classificação THS.

Classificação	Avaliação
THS 0	Não-Câncer
THS 1	Normal
THS 2	Cisto
THS 3	Tumor Benigno
THS 4	Tumor Maligno

O índice THS 0 foi incluído para os casos de avaliação binária: Câncer ou Não-Câncer. Neste caso, a paciente que apresentar THS 0 (Não-Câncer) pode ser portadora de cisto, tumor benigno ou não possuir anormalidades. A classe binária Câncer será representada pelo índice THS 4 (Tumor Maligno).

Para análise de multiclases, o índice THS poderá assumir as categorias de avaliação de 1 a 4, por classificação crescente de risco de malignidade.

O resultado associado ao THS é apresentado no painel **Resultado** (Figura 22). No primeiro espaço aparecerá um número entre 0 e 4, referente ao índice, e no segundo espaço aparecerá a avaliação, conforme a tabela acima.

Figura 22 – Painel Resultado.

Por fim, a classificação é iniciada quando o botão Iniciar Classificação for selecionado. Ao selecionar o botão Salvar Resultado a imagem termográfica de cada paciente será salva assim como os seus dados: prontuário, diagnóstico e data da análise. A Figura 23 mostra os botões de acionamento descritos.

Figura 23 – Botões de acionamento da interface gráfica.



5.2 Análise Quantitativa dos Sistemas de CAD

Para uso dos sistemas de CAD foi utilizada uma amostra balanceada com 98 termogramas (20 pacientes normais, 27 pacientes com tumor benigno, 27 pacientes com tumor maligno e 24 pacientes com cisto).

Na classificação dessa amostra, observou-se que o desempenho do classificador SVM foi baixo para as características c_5 e c_6 , selecionadas como sendo a melhor combinação para a base de dados de Dourado Neto (2014), como será visto mais adiante. A Tabela 4 mostra as características utilizadas neste trabalho e o significado de cada uma. Nesta tabela, $T_{min,MD}$ e $T_{min,ME}$, $T_{max,MD}$ e $T_{max,ME}$ representam as temperaturas mínimas e máximas da mama direita (MD) e da mama esquerda (ME), respectivamente.

Tabela 5 – Lista de características.


Característica	Definição	Característica	Definição
c_1	$\max(T_{max,MD}, T_{max,ME})$	c_6	$c_2 - c_3$
c_2	$\min(T_{max,MD}, T_{max,ME})$	c_7	$c_3 - c_4$
c_3	$\max(T_{min,MD}, T_{min,ME})$	c_{11}	$\max(T_{max,MD}, T_{max,ME})$
c_4	$\min(T_{min,MD}, T_{min,ME})$	c_{13}	$\max(T_{min,MD}, T_{min,ME})$
c_5	$c_1 - c_2$	c_{14}	$\min(T_{min,MD}, T_{min,ME})$

Uma nova seleção de atributos foi realizada com base nas vinte características propostas pelo autor. Para encontrar o melhor par de características para a nova base, foi utilizado o programa WEKA que é um *software* livre e especializado nessa tarefa.

Através deste *software*, verificou-se que as características que apresentaram individualmente melhor resultado na separação das classes Câncer/Não Câncer foram as: c_3, c_6, c_7, c_{13} e c_{14} cujos histogramas são apresentados na Figura 24.

As características c_{13} e c_{14} fazem parte de um conjunto que abrange os atributos c_{11} a c_{18} . Este conjunto foi definido para verificar se o critério de robustez utilizado na busca dos máximos e mínimos de temperatura interfere ou não nas medidas de cada característica. O critério de robustez consiste em considerar *pixels* que apresentam temperatura maior/menor ou igual aos *pixels* vizinhos que não estão localizados na borda da região segmentada.

Figura 24 – Histogramas para seleção de características (Vermelho – Câncer / Azul – Não-Câncer).



A Tabela 5 mostra os resultados da seleção de características utilizando o método *Attribute Ranking* e o analisador *Information Gain Ranking Filter*, disponíveis no programa WEKA.


Tabela 6 – *Ranking* das melhores características.

Posição	Ranked	Característica
1	0,1617	c_3
2	0,1358	c_{14}
3	0,1358	c_{13}
4	0,1348	c_6
5	0,1010	c_7

Os histogramas contidos na Figura 24 foram avaliados para se determinar a característica que melhor separa as duas classes. A característica selecionada foi aquela cujos histogramas apresentaram melhor agrupamento de cada classe e menor sobreposição de valores. Da análise conjunta destes histogramas e da Tabela 4, escolheu-se a característica c_3 como sendo a mais adequada para essa função. A busca da característica que combina com c_3 foi realizada visualmente, através de todas as combinações possíveis, procurando a configuração que resulta na melhor separação da classe Maligno das demais classes.

A combinação c_3 e c_{11} foi escolhida como sendo a que gerou a discriminação mais adequada entre as classes, fornecendo uma menor dispersão destas (Figura 25A). O mesmo não ocorre com as características c_5 e c_6 , testadas inicialmente por Dourado Neto (2014) como sendo a melhor combinação (Figura 25B). Nessas figuras, observa-se que a classe Normal está sobreposta às outras classes, o que dificulta o processo de classificação.

Figura 25 – Espaço de características usado para seleção da melhor combinação.

A) Combinação $[c_3, c_{11}]$ B) Combinação $[c_5, c_6]$ 

A amostra que compõe a base de dados foi classificada com o par de características $[c_3, c_{11}]$ e, como critério de comparação, com o par $[c_5, c_6]$. A Tabela 6 apresenta os resultados obtidos após a classificação da amostra para os dois pares, na qual Sens. e Esp. indicam, respectivamente, a sensibilidade e a especificidade. Para todas as taxas avaliadas, os resultados obtidos pelas características $[c_3, c_{11}]$ foram melhores.

Tabela 7 – Resultados da classificação para os conjuntos de características $[c_3, c_{11}]$ e $[c_5, c_6]$, com *kernel* 7.

Característica	Classificador	Acertos	Sens.	Esp.	Acerto Benigno	Acerto Cisto	Acerto Normal
$[c_3, c_{11}]$	SVM	72,63%	48,15%	82,35%	73,08%	90,91%	85,00%
$[c_5, c_6]$	SVM	54,74%	44,44%	58,82%	61,54%	63,64%	50,00%

Os resultados discutidos até o momento foram gerados utilizando uma função de núcleo polinomial de ordem 7, definida como sendo a mais adequada por Dourado Neto (2015 – Comunicação Pessoal). A fim de encontrar taxas melhores, a ordem deste polinômio foi variada de 7 a 12 e o melhor resultado foi obtido pela ordem 8. Contudo, a taxa Acerto Cisto diminuiu 4,55 pontos percentuais em relação à taxa obtida através do polinômio usado inicialmente. A Tabela 7 contém as taxas encontradas pela classificação com esta nova ordem.

Tabela 8 – Resultados da classificação para um polinômio de ordem 8.

Característica	Classificador	Acertos	Sens.	Esp.	Acerto Benigno	Acerto Cisto	Acerto Normal
$[c_3, c_{11}]$	SVM	74,74%	51,85%	83,82%	80,77%	86,36%	85,00%

Similarmente ao estudo de Araújo (2014), para utilização do classificador Mahalanobis foi necessário estimar os parâmetros de controle λ_1 , λ_2 e λ_3 relacionados, respectivamente, às classes Maligno, Benigno e Cisto. Com a inclusão da classe Normal, também foi estimado o parâmetro λ_4 referente a este grupo. Tal busca foi realizada com o intuito de determinar a combinação dos parâmetros que fornece uma boa taxa de acerto e um alto índice de sensibilidade ao grupo Maligno.

Os valores de cada parâmetro foram variados de 0 até 1, com incremento de (0,1), e todas combinações obtidas foram testadas. O resultado completo apresentou 14.641 combinações diferentes e forneceram os valores buscados das taxas de acerto e da sensibilidade.


A definição da melhor combinação, para os critérios desejados, foi realizada a partir de um estudo dos histogramas exibidos na Figura 26A e na Figura 26B que indicam,

respectivamente, a taxa de acerto geral e a sensibilidade à classe Maligno. Analisando a Figura 26A observa-se que a taxa de acerto mínima foi de 19% e está associada a seguinte faixa de combinação de parâmetros: $\lambda_1 = 0,7$ a $0,9$; $\lambda_2 = 0,6$ a $0,9$; $\lambda_3 = 0,7$ a 1 e $\lambda_4 = 0$. A taxa de acerto máxima foi de 42% para as seguintes combinações de parâmetros: $\lambda_1 = 0$; $\lambda_2 = 1$; $\lambda_3 = 0,6$ e $0,7$ e $\lambda_4 = 1$. Porém, para esta taxa, o índice de sensibilidade ao grupo Maligno foi de apenas 26%.

Dessa maneira, buscou-se nos resultados obtidos uma taxa de acerto global que fosse próxima à máxima encontrada e fornecesse um índice de sensibilidade maior. Na Figura 26B observa-se que a maior sensibilidade à classe Maligno encontrada foi de 93%, associada a uma taxa de acerto de 39%. Os parâmetros escolhidos foram os resultantes dessa combinação escolhida (taxa de acerto + sensibilidade) e é dada por: $\lambda_1 = 0,2$; $\lambda_2 = 0$; $\lambda_3 = 0,8$ e $\lambda_4 = 1$.

Figura 26 – Representação dos histogramas.

A) Taxa de acerto da classificação B) Sensibilidade à classe Maligno



Depois de terminadas as modificações nos classificadores SVM e Mahalanobis, foi feita uma comparação entre eles em relação à precisão dos métodos e à rapidez no retorno do resultado. Analisando os dados da Tabela 8, infere-se que o desempenho do classificador SVM em relação às taxas de acerto foi superior do que o desempenho do classificador Mahalanobis. Este, por sua vez, apresentou uma sensibilidade à classe Maligno 41,15 pontos percentuais maiores que aquele. O valor relacionado à Rapidez do programa executado corresponde ao intervalo de tempo entre o início e o fim do mesmo. Neste caso, o classificador SVM foi, aproximadamente, 3 vezes mais rápido que o classificador Mahalanobis.

Tabela 9 – Comparação entre os classificadores SVM, com *kernel* 8, e Mahalanobis.

Classificador	Acertos	Sens.	Esp.	Acerto Benigno	Acerto Cisto	Acerto Normal	Rapidez
SVM	74,74%	51,85%	83,82%	80,77%	86,36%	85,00%	13,66 s
Mahalanobis	39,00%	93,00%	36,00%	20,00%	43,48%	5,00%	40,56 s


Possivelmente, o classificador SVM apresentou taxas melhores por usar uma classificação binária, enquanto que o classificador Mahalanobis classifica simultaneamente quatro classes distintas. A classificação de uma amostra como sendo Câncer /Não-Câncer, nem sempre indica que dentro da classe Não-Câncer as pacientes com tumores benignos serão realmente classificadas como tal, por exemplo. Isso ocorre, pois o grupo Não-Câncer abrange pacientes normais, com tumores benignos e com cistos.

Dentre todas as classes consideradas, a classe Maligno é a mais preocupante dado que a sensibilidade a ela torna-se um parâmetro de grande importância na detecção do câncer de mama. Porém, observou-se que a inclusão da classe Normal devido à sua grande variabilidade gerou alguns falsos negativos na nova análise, isto é, quando o teste informa incorretamente que o paciente não tem a doença quando de fato tem.

No geral, foram encontradas as seguintes limitações para os classificadores escolhidos:

- SVM: classificação binária (Câncer/Não-Câncer);
- Mahalanobis: baixas taxas de acertos.

Buscando a melhoria e/ou solução destas limitações foram feitos alguns ajustes no processo desenvolvido. A fim de aplicar o SVM em problemas multiclasse, foi utilizada a estratégia *one-versus-all* (OVA) a qual consiste em construir classificadores binários que diferenciam uma das classes das demais, isto é, um modelo binário é criado para cada uma das várias classes de saída. Neste caso, define-se o valor de uma das classes como sendo 1 e as demais terão o valor 0. A Figura 27 exemplifica o método *one-versus-all*.

Figura 27 – Método *one-versus-all*.

Como o presente trabalho envolve 4 classes, foram construídos 4 classificadores distintos que foram usadas para a classificação do grupo teste. O classificador C_i , onde i é o número de classes, é treinado para primeira classe usando-se como contra exemplo as outras classes, e assim por diante. O critério de validação utilizado, também, foi o *leave-one-out* e a decisão final foi obtida através do classificador de maior saída que a atribui à classe correspondente.

A Tabela 9 apresenta os resultados obtidos após a classificação da amostra utilizando o classificador SVM adaptado para multiclases. Foram usados o mesmo par de características (c_3 e c_{11}) e a mesma ordem polinomial (8), pois no teste do par (c_5 e c_6) e ordem polinomial 7 os resultados apresentaram um menor desempenho. Realizando uma comparação com os valores da Tabela 9, observa-se que a sensibilidade ao grupo Maligno aumentou de 14,82 pontos percentuais, enquanto que as taxas de acertos diminuíram. Porém, o método SVM/OVA consegue distinguir as classes contidas no grupo Não-Câncer.

Tabela 10 – Resultado da classificação SVM/OVA, com *kernel* 8.

Classificador	Acertos	Sens.	Esp.	Acerto Benigno	Acerto Cisto	Acerto Normal	Rapidez
SVM/OVA	51,58%	66,67%	82,35%	56,00%	59,09%	20,00%	11,87 s

Para o classificador baseado na distância de Mahalanobis foram selecionadas as características propostas em uma das abordagens estudadas por Araújo (2014). Neste caso, foram obtidas características contínuas que representam as diferenças de temperaturas das mamas esquerda e direita (Equações 5.1, 5.2 e 5.3), obtidas das matrizes de segmentação. E características obtidas através da diferença entre os valores máximos das temperaturas das matrizes morfológicas M_{MD} e M_{ME} (Equação 5.4).

$$|T_{max_{MD}} - T_{max_{ME}}| \quad (5.1)$$

$$|T_{min_{MD}} - T_{min_{ME}}| \quad (5.2)$$

$$|\min(T_{min_{MD}} - T_{min_{ME}}) - \max(T_{max_{MD}} - T_{max_{ME}})| \quad (5.3)$$

$$|\max M_{MD} - \max M_{ME}| \quad (5.4)$$

O classificador de distância mínima d_m calculada através da distância de Mahalanobis é, agora, definido como sendo:

$$d_m(x, u_i) = \sqrt{(x - u_i)^T \Sigma_i^{-1} (x - u_i)} \quad (5.5)$$

onde:

x =padrão desconhecido;

u_i =protótipo de uma classe ω_i e consiste no vetor de médias de seus elementos;

Σ_i =matriz de covariâncias para a classe ω_i .

A Tabela 10 contém os resultados obtidos no processo de classificação baseado em características contínuas (CC). Comparando os valores desta tabela com os da Tabela 6 para o classificador Mahalanobis, observa-se que a sensibilidade à classe Maligno diminuiu cerca de 52 pontos percentuais, enquanto que a especificidade a este grupo aumentou de 22,33 pontos percentuais. Porém, com exceção da taxa Acerto Cisto, todas demais taxas de acerto

tornaram-se maiores, em especial a taxa Acerto Normal. O valor relacionado com a rapidez do programa foi reduzido de, aproximadamente, 7 vezes.

Tabela 11 – Resultado da classificação Mahalanobis CC.

Classificador	Acertos	Sens.	Esp.	Acerto Benigno	Acerto Cisto	Acerto Normal	Rapidez
Mahalanobis CC	52,04%	40,74%	58,33%	66,67%	39,13%	40,00%	5,58 s

O aumento de alguns valores encontrados pelo classificador Mahalanobis CC pode ser justificada pela minimização dos efeitos da grande variabilidade da classe Normal, através do uso de distâncias ponderadas pela máxima variância da classe (SILVA, 2015). Neste caso, um indivíduo que está à mesma distância de diversas classes, quando projetado no espaço de características, é designado àquela classe cuja variância é máxima (SILVA et al., 2015b).

Aplicando o estudo da minimização da variabilidade no uso das características intervalares do classificador Mahalanobis parametrizado, observou-se que a taxa de acerto máxima também foi de 42% para as seguintes combinações de parâmetros: $\lambda_1 = 0$; $\lambda_2 = 0,2$; $\lambda_3 = 0,6$ e $\lambda_4 = 0,7$ a 1. Para esta taxa, o índice de sensibilidade à classe Maligno foi de 62,96%, aumentando 36,96 pontos percentuais em relação ao estudo inicial deste classificador.

Os sistemas de CAD discutidos até então foram ajustados para que o processo de classificação fosse realizado para uma única paciente. Em seguida, eles foram implementados em uma interface gráfica de usuário para maior aplicabilidade no auxílio ao diagnóstico do câncer de mama.

5.3 Estudo de Casos

Dando seguimento a este capítulo são apresentadas aplicações da interface gráfica de usuário: ANALISE IR_MAMA. Foram testados os classificadores baseados na distância Mahalanobis, tanto com o ajuste da variabilidade da classe Normal como sem este ajuste. Nesta primeira versão da interface desenvolvida, também foram realizadas análises preliminares usando o classificador SVM/OVA e o classificador Mahalanobis/CC.


No presente trabalho, as imagens referentes aos resultados da classificação das pacientes apresentam os valores obtidos através dos classificadores SVM e Mahalanobis (com a minimização da variabilidade da classe Normal).

5.2.1 Estudo de caso 1: paciente normal

A paciente possui 52 anos e teve seu diagnóstico concluído através de exame clínico, de ultrassonografia e de mamografia. Seu exame de mamografia indicou BI-RADS 1, que significa que não há anormalidades presente em suas mamas.

Primeiramente, foram preenchidos os dados da paciente com informações importantes para futuras análises e para facilitar a busca dos registros de cada pessoa submetida ao exame termográfico. Em seguida, selecionou-se o tipo de segmentação desejada e o botão **Iniciar Classificação** foi acionado para dar início ao processamento. A Figura 28 mostra o painel **Informações do Paciente** devidamente preenchido, nele a letra F indica o gênero feminino.

Figura 28 – Dados da Paciente 1.



Informações do Paciente


Número do Prontuário	1628496-3		
Data da Análise	08	03	2016
Idade	52	Gênero	F

A Figura 29 mostra os resultados da segmentação semiautomática (Figura 29B) e da segmentação automática (Figura 29C), bem como a imagem termográfica escolhida para análise (Figura 29A). Observa-se que na segmentação automática houve uma pequena perda da região das mamas, fato este que não ocorre na segmentação semiautomática.

Quanto ao tempo de duração de cada processo de segmentação dura até fornecer o seu resultado final, tem-se que: a segmentação semiautomática durou 58,8s devido, principalmente, a etapa de seleção manual de cada mama; e a segmentação automática foi aproximadamente 13 vezes menor que a outra, com duração de 4,67s.

Figura 29 – Regiões segmentadas da Paciente 1.

A) Imagem termográfica B) Segmentação semiautomática C) Segmentação automática



Para avaliações binárias (Câncer e Não-Câncer), foi acrescentado o valor zero ao THS (vide Tabela 3) para indicar a classe Não-Câncer. Ao apresentar o $THS = 0$, a paciente pode ser portadora de um cisto, de tumor benigno ou ter mama normal.

Ao se clicar o botão **Iniciar Classificação**, como o próprio nome diz, a etapa de classificação da paciente também é realizada. Devido à agilidade em fornecer os resultados e à forma mais direta de exibi-los, o classificador SVM pode ser usado numa triagem rápida de pacientes, separando os grupos de risco e de não risco.

A Figura 30 mostra a forma que a decisão final da classificação SVM é exibida no painel **Resultado**. O resultado fornecido pelo *software* é um verdadeiro negativo, pois a

paciente foi classificada com ausência de tumor maligno e de fato não o tem. A Figura 31 apresenta o resultado obtido através da utilização do classificador Mahalanobis ajustado para minimizar os efeitos da variabilidade da classe Normal. Neste caso, apesar de não ter acertado o real diagnóstico da paciente, o resultado também foi um verdadeiro negativo.

Figura 30 – Resultado da Paciente 1 usando o classificador SVM.






Figura 31 – Resultado da Paciente 1 usando o classificador Mahalanobis com minimização da classe Normal.



A imagem termográfica com as informações da paciente e do resultado obtido foi salva em formato *png* quando se clicou no botão **Salvar Resultado**. Esta figura pode ser impressa e anexada ao prontuário médico da paciente, juntamente com os demais exames. A Figura 32 ilustra o termograma que foi salvo nesta operação.

Figura 32 – Imagem salva da Paciente 1 com o resultado do classificador SVM.



5.2.2 Estudo de Caso 2: paciente com tumor benigno


A paciente possui 42 anos e foi diagnosticada com um fibroadenoma mamário, a partir do exame de biópsia, indicando a presença de um tumor benigno na mama desta mulher. Os dados da paciente foram devidamente preenchidos conforme as solicitações do painel **Informações do Paciente** (Figura 33). As regiões de interesse foram segmentadas de forma semiautomática e automática, e elas estão apresentadas na Figura 34.

Figura 33 – Dados da Paciente 2.

Informações do Paciente			
Número do Prontuário	1732575-2		
Data da Análise	08	03	2016
Idade	42	Gênero	F

Figura 34 – Regiões segmentadas da Paciente 2.

A) Imagem termográfica B) Segmentação semiautomática C) Segmentação automática



Apesar de a segmentação automática (Figura 34C) não ter detectado corretamente a parte da borda inferior das mamas, ela apresentou um resultado considerado bom, por não ter desprezado nenhuma parte considerada importante na região de interesse. Em relação ao tempo de duração do processo de segmentação tem-se: 53,33s para a semiautomática e 1,89s para a automática.

O resultado da etapa de classificação utilizando o classificador SVM está exibido na Figura 35. A Figura 36 exhibe o resultado do uso do classificador Mahalanobis e, da mesma forma que a paciente anterior, este classificador não acertou o seu real diagnóstico. Para ambos os classificadores foi obtido um verdadeiro negativo, pois a paciente efetivamente não possui tumor maligno.

A Figura 37 apresenta a imagem termográfica salva com os dados obtidos e inseridos na avaliação da paciente.

Figura 35 – Resultado da Paciente 2 usando o classificador SVM.




Figura 36 – Resultado da Paciente 2 usando o classificador Mahalanobis com minimização da classe Normal.






Figura 37 – Imagem salva da Paciente 2 com o resultado do classificador SVM.



5.2.3 Estudo de Caso 3: paciente com cisto

A paciente de 38 anos foi diagnosticada por exames clínicos e ultrassonografia com alteração benigna, do tipo cisto bilateral, nas mamas. Similarmente a análise realizada nos casos anteriores, foram inseridos os dados da paciente e suas imagens foram segmentadas pelos dois métodos implementados na interface gráfica. A Figura 38 e Figura 39 exibem, respectivamente, as informações da paciente e os resultados do processo de segmentação.

Figura 38 – Dados da Paciente 3.




Informações do Paciente

Número do Prontuário	1509718-3		
Data da Análise	08	03	2016
Idade	38	Gênero	F

Figura 39 – Regiões segmentadas da Paciente 3.

A) Imagem termográfica B) Segmentação semiautomática C) Segmentação automática





Analisando a Figura 39C observa-se que, da mesma forma que o Estudo de Caso 2, a segmentação automática foi um pouco ineficiente na detecção da borda inferior da mama. Porém, seu resultado foi considerado bom por não ter descartado regiões das mamas que são importantes para a etapa de classificação. A duração do processo de segmentação foi: 56,08s para a semiautomática e 4,47s para a automática.

O resultado da etapa de classificação foi um verdadeiro negativo para o classificador SVM (Figura 40). Para o classificador Mahalanobis, o resultado foi um falso positivo, pois a paciente foi classificada com presença de tumor maligno quando, na verdade, não o tem (Figura 41). A Figura 42 exibe a imagem salva ao se clicar o botão **Salvar Resultado**.

Figura 40 – Resultado da Paciente 3 usando o classificador SVM.




Figura 41 – Resultado da Paciente 3 usando o classificador Mahalanobis com minimização da classe Normal.





Figura 42 – Imagem salva da Paciente 3 com o resultado do classificador SVM.



5.2.4 Estudo de Caso 4: pacientes com tumor maligno


Através da biópsia, foi confirmado que a paciente de 35 anos possui um tumor maligno, *carcinoma ductal* invasivo, em sua mama. A Figura 43 e a Figura 44 exibem, respectivamente, os dados da paciente avaliada e os resultados das segmentações das áreas de interesse da imagem termográfica digital.

Figura 43 – Dados da Paciente 4.

Informações do Paciente			
Número do Prontuário	1607570-1		
Data da Análise	08	03	2016
Idade	35	Gênero	F

Figura 44 – Regiões segmentadas da Paciente 4.

A) Imagem termográfica B) Segmentação semiautomática C) Segmentação automática



A segmentação automática (Figura 44) novamente apresentou problemas na detecção das bordas inferiores das mamas, porém isto não comprometeu a extração da região de interesse. A duração do processo da segmentação automática foi de 1,63s e da segmentação semiautomática foi de 45,39s.

O resultado fornecido pelo *software*, utilizando ambos classificadores, foi um verdadeiro positivo (Figura 45 e Figura 46), pois a paciente foi classificada com a presença de tumor maligno e de fato ela o possui.

A Figura 47 apresenta imagem termográfica que foi armazenada ao clicar o botão **Salvar Resultado**.

Figura 45 – Resultado da Paciente 4 usando o classificador SVM.




Figura 46 – Resultado da Paciente 4 usando o classificador Mahalanobis com minimização da classe Normal.






Figura 47 – Imagem salva da Paciente 4 com o resultado do classificador SVM.



A seguir apresenta-se um caso cuja classificação da paciente com tumor maligno foi incorreta utilizando o classificador SVM, visto que para este classificador os testes exibidos até o momento foram condizentes com os diagnósticos já conhecidos. Esta paciente possui 57

anos e foi diagnosticada por exames clínicos, ultrassonografia, mamografia e biópsia com a presença de um *carcinoma ductal* invasivo. A Figura 48 mostra os dados da paciente avaliada e a Figura 49 indica o resultado obtido.


Figura 48 – Dados da Paciente5.



Informações do Paciente

Número do Prontuário	1783156-9
Data da Análise	08 03 2016
Idade	57
Gênero	F

Figura 49 – Resultado da Paciente5 usando o classificador SVM.



Resultado

THS	0	Não Câncer
-----	---	------------

Neste caso, foi gerado um falso negativo, pois foi sugerido que a paciente não tem o problema quando na verdade o tem. Este erro deve ser tratado com bastante cuidado, uma vez que pode acarretar problemas mais graves como, por exemplo, a procrastinação do tratamento do câncer. Por isso, não só este como os demais métodos de detecção do câncer de mama são analisados em conjunto, a fim de que a probabilidade de se ter um falso negativo ou um falso positivo diminua cada vez mais.

Síntese dos resultados obtidos

A Tabela 11 apresenta os resultados encontrados no estudo de casos de todas as pacientes analisadas, bem como os resultados da utilização dos classificadores baseados nas distâncias de Mahalanobis. Os resultados obtidos pelos classificadores SVM/OVA e Mahalanobis/CC não foram validados, necessitando de um estudo mais aprofundado. Nesta tabela, os classificadores Mahalanobis1 e Mahalanobis 2 representam, respectivamente, o método que possui o ajuste da variabilidade da classe normal e o método que não possui.

Tabela 12 – Resultados obtidos na classificação das pacientes estudadas.

Pacientes	Idade	Diagnóstico	Métodos de Classificação		
			SVM/Binário	Mahalanobis1	Mahalanobis2
Paciente 1	52	Normal	THS 0	THS 2	THS 2
Paciente 2	42	Tumor Benigno	THS 0	THS 1	THS 4
Paciente 3	38	Cisto	THS 0	THS 4	THS 4
Paciente 4	35	Tumor Maligno	THS 4	THS 4	THS 4
Paciente 5	57	Tumor Maligno	THS 0	THS 4	THS 4


5.4 Painel Estatística e Função Help


A fim de avaliar as funções disponíveis da interface ANALISE IR_MAMA foram inseridos no painel **Estatística** alguns dados fictícios no arquivo onde as informações das pacientes e seus resultados são salvos. Estes dados incluem um período que abrange o ano de 2015 a 2019 e diversos diagnósticos diferentes.

A primeira opção **Casos Clínicos** gera um gráfico pizza que mostra o quantitativo, em porcentagem do gráfico inteiro, dos diagnósticos registrados no período definido previamente. A Figura 46A e a Figura 46B exibem, respectivamente, os casos clínicos para o ano de 2015 e para os anos 2015 a 2019.

Figura 50 – Gráficos pizzas de distribuição de casos clínicos

A) Período: 2015 B) Período: 2015 a 2019







A segunda opção **Casos clínico × Idade** apresenta histogramas que relacionam a frequência de determinada faixa etária para cada caso clínico. A Figura 47A e a Figura 47B exibem, respectivamente, os histogramas para o ano de 2015 e para os anos 2015 a 2019.

A partir das análises realizadas com a primeira e com a segunda opção do painel **Estatística** é possível se ter uma estimativa de qual classe apresentou maior recorrência em determinado período e, também, determinar a faixa etária na qual cada caso clínico tem maior prevalência.

Figura 51 – Histogramas Idade × Frequência de cada caso clínico.

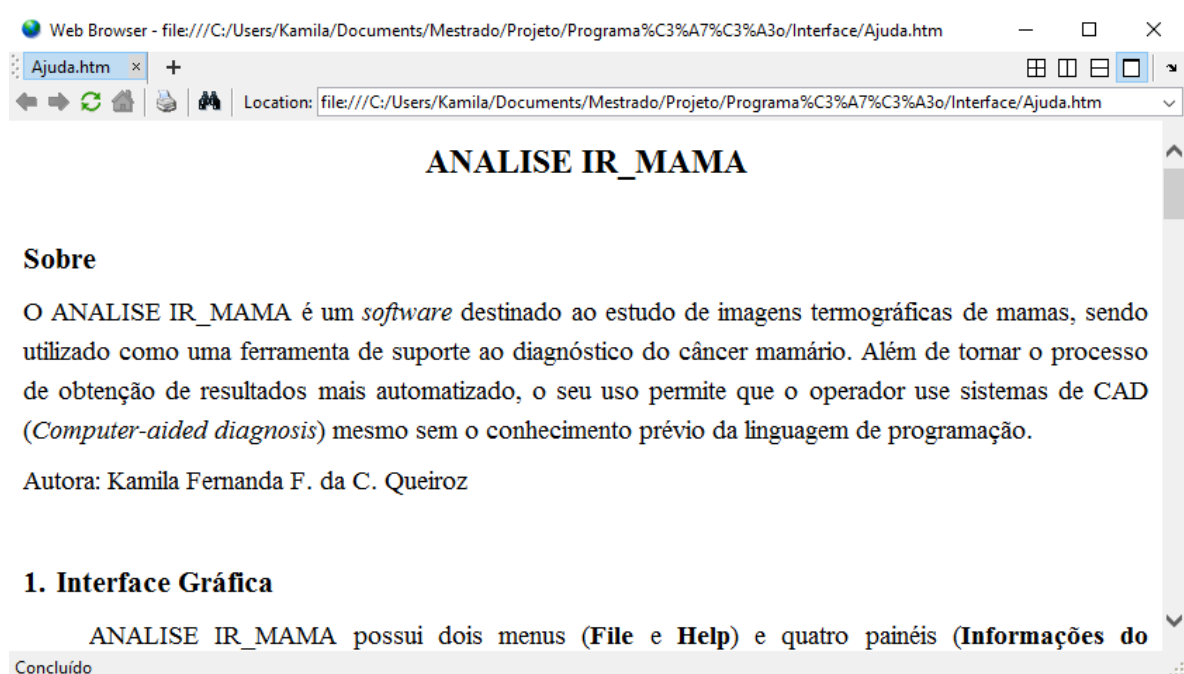
A) Período: 2015 B) Período: 2015 a 2019





Por fim, no menu **Help** foram inseridas as informações necessárias da interface gráfica para que, quando necessário, o usuário entenda o funcionamento de cada componente da GUI. A Figura 48 ilustra a tela que é aberta quando esse menu é selecionado.

Figura 52 – Tela do menu Help.



6 CONCLUSÕES E TRABALHOS FUTUROS

A ferramenta computacional ANALISE IR_MAMA desenvolvida no presente trabalho:

- Agregou de forma eficiente e simples opções de segmentação (automática e semiautomática) de imagens termográficas de mama, assim como classificação de patologias mamárias;
- Apresentou um novo índice THS (*Thermal Statistical Index*) de classificação de anomalias mamárias, baseado no resultado obtido na classificação estatística;
- Introduziu uma nova classe (Normal) na classificação estatística baseada em variáveis intervalares proposta por Araújo (2014), apesar de ainda precisar de alguns ajustes devido à grande variabilidade desta classe;
- Usou uma base de dados ampliada (98 pacientes com diagnóstico concluído) em relação a trabalhos anteriores do grupo de pesquisa;
- Utilizou um par de variáveis associado à técnica de segmentação automática que foi escolhido por meio do *software* livre WEKA. Os conjuntos de variáveis obtidos foram utilizados como entrada dos respectivos métodos de classificação usados;
- Avaliou a possibilidade de adaptação do classificador SVM binário para uma análise de multiclases;
- Os desempenhos dos métodos foram avaliados através dos seus índices de sensibilidade e especificidade à classe Maligno, bem como das taxas de acerto das demais classes;
- Apresentou um diferencial que foi o ajuste dos sistemas de CAD desenvolvidos para análise de uma única paciente. Neste sentido, a aplicação da interface gráfica ANALISE IR_MAMA para avaliação individual de pacientes escolhidos aleatoriamente mostrou-se adequada para o classificador SVM, apesar da possibilidade de gerar falsos negativos em alguns casos.

Baseada nestas considerações espera-se que o uso da termografia associado a uma ferramenta de análise de disfunções mamárias possa colaborar no diagnóstico precoce do câncer de mama, sendo fundamental em uma triagem prévia, e possa aumentar a acurácia deste diagnóstico quando associada aos métodos tradicionais (mamografia e biópsia).

Como trabalhos futuros, pode-se sugerir:

- Testar e analisar novas estratégias para os classificadores estatísticos utilizados, como a adequação do SVM de classificação binária para um SVM de classificação multiclases, a fim de encontrar o melhor resultado possível para análise individual de pacientes;
- Aperfeiçoar a interface gráfica de usuário, a partir da inclusão de novos módulos computacionais de interesse para executar simulações computacionais, os novos módulos podem executar mapeamento de textura usando as imagens termográficas (SANTOS, 2014), avaliar propriedades termofísicas e perfusões sanguíneas usando técnicas desenvolvidas por Bezerra (2013) ou analisar qual a melhor prótese mamária externa para determinada paciente (VIANA, 2010);
- Tratar a amostra desbalanceada a partir do uso de Sistemas de Múltiplos Classificadores (MCSs – *Multiple Classifier Systems*) baseados na adaptação de algoritmos de aprendizagem;
- Criar três versões da interface gráfica que incluam programas que permitam uma triagem mais rápida, uma versão mais adequada ao uso médico e uma versão mais completa destinada aos pesquisadores.

REFERÊNCIAS BIBLIOGRÁFICAS

ACHARYA, U. R.; NG, E. Y. K.; TAN, J.; SREE, S.V. Thermography Based Breast Cancer Detection Using Texture Features and Support Vector Machine. **Journal of Medical Systems**, v. 36, n. 3, p. 1503–1510, 2010.

ACHARYA, U. R.; NG, E. Y. K.; SREE, S. V.; CHUA, C. K.; CHATTOPADHYAY, S. Higher order spectra analysis of breast thermograms for the automated identification of breast cancer. **Expert Systems**, v. 31, n. 1, p. 37–47, 2014.

ALBUQUERQUE NETO, C. **Modelo integrado dos sistemas térmico e respiratório do corpo humano**. p. 188. Tese (Doutorado) - Universidade de São Paulo, São Paulo, 2010.

AMMER, K.; RING, E. F. Standard Procedures for Infrared Imaging in Medicine. In: BRONZINO, J. D. (Eds.) Medical Devices and Systems, **The Biomedical Engineering Handbook**, CRC Press, Connecticut. p. 36-1 – 36-14, 2006.

ARAÚJO, M. C. DE. **Uso de imagens termográficas para classificação de anormalidades de mama baseado em variáveis simbólicas intervalares**. p. 162. Tese (Doutorado) - Universidade Federal de Pernambuco, Recife, 2014.

ARORA, N.; MARTINS, D.; RUGGERIO, D.; TOUSIMIS, E.; SWISTEL, A. J.; OSBOURN, M. P.; SIMMONS, R. M. Effectiveness of a noninvasive digital infrared thermal imaging system in the detection of breast cancer. **The American Journal of Surgery**, v. 196, n. 4, p. 523–526, 2008.

BARNES, R.B. Thermography of the Human body. **Science**, v. 140, p. 870–877. 1963.

BEZERRA, L. A. **Estimativa de parâmetros termofísicos da mama e de distúrbios mamários a partir da termografia por infravermelho utilizando técnicas de otimização**. p. 171. Tese (Doutorado) - Universidade Federal de Pernambuco, Recife, 2013.

BIRNBAUM, S.J.; KLIOT, D. Thermography-obstetrical applications. **Annals of the New York Academy of Sciences**, v. 121, p.209–222, 1964.

BOCK, H. H.; DIDAY, E. **Analysis of Symbolic Data: Exploratory Methods for Extracting Statistical Information form Complex Data**. New Jersey. USA: Springer - Verlag. New York, 2000.

BORCHARTT, T. B. **Análise De Imagens Termográficas Para a Classificação De Alterações Na Mama**. p. 115. Tese (Doutorado) - Universidade Federal Fluminense, Rio de Janeiro, 2013.

BRIOSCHI, M. **Metodologia de normalização de análise do campo de temperaturas em imagem infravermelha humana**. p. 115. Dissertação (Mestrado) — Universidade Federal do Paraná, Curitiba, 2011.

CASTLEMAN, K. N. **Digital image processing**. New Jersey: Prentice-Hall, 1996.

CHARNY, C. K. Mathematical models of bioheat transfer. In: Y. I. Cho. Eds. **Advances in Heat Transfer**. USA, v. 22, p. 19-156, 1992.

CHATO, J.C. **Heat transfer to blood vessels**, J. Biomech. Engr., 102, p. 110-118, 1980.

CHAPMAN, S. J. **Programação em MATLAB® para engenheiros**. Thomson. São Paulo, 2003.

COTRIM, D. S.; SILVA, A. M. M.; BEZERRA, E. A. Infra-estrutura de informática para sistemas de apoio ao diagnóstico aplicada a servidores pacs. **III-SIIM**, p. 1–4, 2007.

CRUZ, R. M. O. **Análise de técnicas de extração de características para o reconhecimento de dígitos manuscritos**. p. 37. Trabalho de Conclusão de Curso - Universidade Federal de Pernambuco, Recife, 2008.

DEVIJVER, P.A. E KITTLER J. **Pattern Recognition: A Statistical Approach**. Prentice-Hall, Londres, 1982.

DIAKIDES, N.; DIAKIDES, M; LUPO, J.; PAUL, J.; BALCERACK, R. Advances in Medical Infrared Imaging, in BRONZINO, J. D. Eds., **Medical Devices and Systems, The Biomedical Engineering Handbook**, CRC Press, Connecticut, p. 19-1 – 19-14, 2006.

DILLER, K. R. Modeling of bioheat transfer processes at high and low temperatures. In: CHO, Y. I., ed., **Advances in Heat Transfer: Bioengineering Heat Transfer**, Academic Press, Inc., v. 22, p. 157–357, 1982.

DOUGHERTY, G. **Digital Image Processing for Medical Applications**. 1. ed. Cambridge University Press, New York, 2009.

DOURADO NETO, H. M. **Segmentação e análise automáticas de termogramas: um método auxiliar na detecção do câncer de mama um método auxiliar na detecção do câncer de mama**. p. 99. Dissertação (Mestrado) - Universidade Federal de Pernambuco, Recife, 2014.

DOURADO NETO, H. M. **Classificação**. [mensagem pessoal]. Mensagem recebida por <hugodouradoneto@gmail.com> em 01 set. 2015.

ETO, T. K.; RUBINSKY, B. Bioheat transfer. In: BERGER, S. A.; GOLDSMITH, W.; LEWIS, E.R. Eds. **Introducion to Bioengineering**, Oxford University Press, p. 203-227, 1996.

FERREIRA, M. R. P. **Análise discriminante clássica e de núcleo: avaliações e algumas contribuições relativas aos métodos Boosting e Bootstrap**. Dissertação (Mestrado) — Universidade Federal de Pernambuco, Recife, 2007.

FRONER, A. P. P. **Caracterização de nódulos pulmonares em imagens de tomografia computadorizada para fins de auxílio ao diagnóstico**. p. 128. Dissertação (Mestrado) - Universidade Católica do Rio Grande do Sul, Porto Alegre, 2015.

FURUICHI, M.; MAKIE, T.; HONMA, Y.; ISODA, T.; MIYAKE, S. Laboratory-Confirmed

Dengue Fever and Chikungunya Fever Cases at the Narita Airport Quarantine Station in 2013. **Japanese Journal of Infectious Diseases**, v. 68, n. 2, p. 142–144, 2015.

FURUIE, S.S.; GUTIERREZ, M.A.; BERTOZZO, N.B.; FIGUEIREDO J.C.B.; YAMAGUTTI, M. “Archiving and Retrieving Long-Term Cineangiographic Images in a PACS”. **Computers in Cardiology**, v.26, p.435-438, 1999.

GONZALEZ, R. C.; WOODS, R. E.; EDDINS, E. L. **Digital Image Processing Using Matlab**. New Jersey: Pearson Prentice Hall, 2004.

HARDY, J.D. The radiation of heat from the human body. I–IV, **Journal of Clinical Investigation**, 13. p. 593–620 & 817–883, 1934.

HARDY, J.D.; MUSCHENHEIM, C. The radiation of heat from the human body. V, **Journal of Clinical Investigation**, 15. p. 1–8, 1936.

HOSAKI, Y.; MITSUNOBU, F.; ASHIDA, K.; TSUGENO, H.; OKAMOTO, M.; NISHIDA, N.; TAKATA, S.; YOKOI, T.; TANIZAKI, Y.; OCHI, K.; TSUJI, T. Non-invasive study for peripheral circulation in patients with diabetes mellitus. **Annual reports of Misasa Medical Branch**, v. 72, p. 31–37, 2002.

HOUDAS, Y. ; RING, E.F.J. **Human Body Temperature**, Plenum Press, New York, 1982.

INCA. **Instituto Nacional de Câncer José Alencar Gomes da Silva** Estimativas 2008: Incidência de Câncer no Brasil. Rio de Janeiro, Brasil: Ministério da Saúde, 2007.

INCA. **Instituto Nacional de Câncer José Alencar Gomes da Silva** Estimativas 2014: Incidência de Câncer no Brasil. Rio de Janeiro, Brasil: Ministério da Saúde, 2014.

INCA. **Instituto Nacional de Câncer José Alencar Gomes da Silva**. Ministério da Saúde. Disponível em: <<http://www2.inca.gov.br/wps/wcm/connect/tiposdecancer/site/home/mama>>. Acesso em 06 de outubro de 2015.

JUNG, A.; ZUBER, J.; RING F. **A Case Book of Infrared Imaging in Clinical Medicine**, MedPress. Warszawa, 2003.

KAPOOR, P.; PRASAD, S. V. A. V.; PATNI, S. Image Segmentation and Asymmetry Analysis of Breast Thermograms for Tumor Detection. **International Journal of Computer Application**, v. 50, n. 9, p. 40–45, 2012.

LAHIRI, B.B., BAGAVATHIAPPAN S., JAYAKUMAR T., PHILIP, J. Medical applications of infrared thermography: A review. **International Journal Infrared Physics and Technology**. p. 222-232, 2012.

LAHIRI, B. B.; BAGAVATHIAPPAN, S.; SOUMYA, C.; JAYAKUMAR, T.; PHILIP, JOHN. Infrared thermography based studies on mobile phone induced heating. **Infrared Physics & Technology**, v. 71, n. November, p. 242–251, 2015.

LIU, C.; HEIJDEN, F.; KLEIN, M. E.; BAAL, J. G., BUS, S. A.; NETTEN, J. J. Infrared dermal thermography on diabetic feet soles to predict ulcerations: a case study. **Advanced**

Biomedical and Clinical Systems XI, v. 8572, p. 85720N, 2013.

LORENA, A. C.; CARVALHO, A. C. P. L. F. Uma Introdução às Support Vector Machines. **Revista de Informática Teórica e Aplicada**, v. 14, n. 2, p. 43–67, 2007.

MANGINAS, A.; ANDREANIDES, E.; LEONTIADIS E.; SFYRAKIS, P.; MAOUNIS, T.; DEGIANNIS, D.; ALIVIZATOS, P.; COKKINOS, D. Right ventricular endocardial thermography in transplanted and coronary artery disease patients: first human application. **Journal of Invasive Cardiology**, n. 22, p. 400–404, 2010.

MARQUES, P. M. A. Diagnóstico auxiliado por computador na radiologia. **Radiologia Brasileira**, v. 34, n. 5, p. 285–293, 2001.

MENCZER J.; ESKIN, B.A. Evaluation of postpartum breast engorgement by thermography. **Magazine Obstetrics and Gynecology**, v. 33, n. 2, p. 260-263, 1969.

MÜLLER, L.S.L. **Segmentação em ultra-sonografia de mama com operadores morfológicos associados à função gaussiana**. Dissertação (Mestrado) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2007.

NG, E. Y. K.; KEE, E.C.; ACHARYA, R.U. Advanced Technique in Breast Thermography Analysis, **Proceedings of the 2005 IEEE Engineering in Medicine and Biology**, 27th Annual Conference Shanghai. China, p. 710-713, 2005.

NG, E. Y. K.; SUDARSHAN, N. M. Computer simulation in conjunction with medical thermography as an adjunct tool for early detection of breast cancer. **BMC Cancer**, v. 4, 2004.

NG, E. Y. Is thermal scanner losing its bite in mass screening of fever due to SARS? **Med Phys**, v. 32, n. 1, p. 93–97, 2005.

NG, E. Y. K. A review of thermography as promising non-invasive detection modality for breast tumor. **International Journal of Thermal Sciences**, v. 48, n. 5, p. 849–859, 2009.

NGUYEN, A.V.; COHEN, N.J.; LIPMAN, H.; BROWN, C.M.; MOLINARI, N.A.; JACKSON, W.L. KIRKING, H. P.; SZYMANOWSKI, T.W.; WILSON, B.A; SALHI, R.R.; ROBERTS, D.W.; STRYKAR, D.B. Comparison of 3 infrared thermal detection systems and self-report for mass fever screening. **Emerging Infectious Diseases**, 16. p. 1710–1717, 2010.

NISHIKAWA R. M. Computer-aided detection and diagnosis. In **Digital Mammography**, Springer Berlin Heidelberg, p. 85-106, 2010

NISHIURA, H.; KAMIYA. Fever screening during the influenza (H1N1-2009) pandemic at Narita International Airport, Japan, **BMC Infectious Diseases**. p. 11–121, 2011.

NOGUEIRA, C. H. F. V.; NOGUEIRA, C. F.; ELY, J. B. Termografia por Infravermelho em Cirurgia Plástica – Novos Horizontes. **Pan American Journal Medical Thermology**, v. 2, n. 1, p. 81–87, 2015.

OLIVEIRA, L. F. M. **Avaliação de técnicas de processamento de imagem e extração de**

características em imagens de pulmão e de coluna vertebral. [s.l.] Universidade Estadual de Londrina, 2015.

OLIVEIRA, M. M. **Desenvolvimento de protocolo e construção de um aparato mecânico para padronização da aquisição de imagens termográficas de mama.** p. 104. Dissertação (Mestrado) — Universidade Federal de Pernambuco, Recife, 2012.

OSELAME, G. B.; NEVES, E. B.; SANCHES, I. J. Desenvolvimento de hardware e software para acompanhamento de lesões dermatológicas. **XXIV Congresso Brasileiro de Engenharia Biomédica.** p. 110–113. 2014.

PEREIRA, F.S.C. **História da Engenharia,** 2013. Disponível em: <<http://www.crea-rn.org.br/artigos/ver/120>>. Acesso em 05 de outubro de 2015.

PINHO, S. R. A. **Apoio ao Diagnóstico de Imagens de Mamografia por Técnicas Computacionais.** p. 75. Dissertação (Mestrado) - Universidade do Porto, 2015.

PORTO, F. N. **Análise de sensibilidade de um sistema CAD para mamografia digital.** p. 68. Dissertação (Mestrado) - Universidade Federal de Minas Gerais, Belo Horizonte, 2010.

QUEIROZ, K. F. F. C. **Análise da repetitividade e melhoria de segmentação semiautomática de ROIs em imagens termográficas de mama.** p. 40. Trabalho de Conclusão de Curso - Universidade Federal de Pernambuco, Recife, 2014.

RESMINI, R.; CONCI, A.; BORCHARTT, T.B.; LIMA, R.C.F., MONTENEGRO, A.A.; PANTALEÃO, C.A. Diagnóstico precoce de doenças mamárias usando imagens térmicas e aprendizado de máquina. **Revista Eletrônica do Alto Vale do Itajaí,** 01. p. 55-67, 2012.

RING, F. Thermal imaging today and its relevance to diabetes. **Journal of Diabetes Science and Technology,** 4. p. 857–862, 2010.

RODRIGUES, C. I. H. **Sistemas CAD em Patologia Mamária.** Dissertação (Mestrado) - Universidade do Porto, Coimbra, 2008.

RUSS, J. C. **The image processing handbook,** 6 ed., CRC Press, 2011.

SANTOS, E. B.; BIANCO, H. T.; BRIOSCHI, M. L. Thermography in Assessing Cardiovascular Risk. **Pan American Journal Medical Thermology,** v. 2, n. 1, p. 23–25, 2015.

SANTOS, L. C. **Plataforma computacional para análise de imagens termográficas visando a detecção e a caracterização de anomalias mamárias.** p. 128. Tese (Doutorado) - Universidade Federal de Pernambuco, Recife, 2014.

SANTOS, S. K. S. L.; LIMA, R. C. F.; CANDEIAS, A. L. B.; CANUTO, G. H.; VIEIRA, J. W. Análise do campo de temperaturas em tumores de próstata submetidos a hipertermia utilizando o Método dos Volumes Finitos e desenvolvimento de uma metodologia usando técnicas Monte Carlo a ser usada para a validação da análise numérica. **8º Congresso Iberoamericano de Ingeniería Mecánica,** n. Mc, p. 1207–1217, 2007.

SCHAEFER, G.; NAKASHIMA, T. Strategies for Addressing Class Imbalance in Ensemble Classification of Thermography Breast Cancer Features. **IEEE Congress on Evolutionary Computation**, p. 2362–2367, 2015.

SCHAEFER, G.; ZÁVIŠEK, M.; NAKASHIMA, T. Thermography based breast cancer analysis using statistical features and fuzzy classification. **Pattern Recognition**, v. 42, n. 6, p. 1133–1137, 2009.

SILVA, A. S. V.; ARAÚJO, M. C. DE; LIMA, R. DE C. F. Avaliação da utilização da termografia como ferramenta de triagem de câncer de mama em mulheres residentes em regiões com poucos recursos médicos. **Encontro Nacional de Engenharia Biomecânica - ENEBI 2015**, 2015b.

SILVA, A. S. V. **Classificação e segmentação de termogramas de mama para triagem de pacientes em regiões de poucos recursos médicos**. p. 95. Dissertação (Mestrado) - Universidade Federal de Pernambuco, Recife, 2015.

SILVA, J. D. **Modelagem Computacional dos Efeitos da Termoterapia Transpupilar em Tumores Oculares Através do Método dos Volumes Finitos em Malhas Não Estruturadas**. p. 173. Tese (Doutorado) - Universidade Federal de Pernambuco, Recife, 2012.

SILVA, K. P. **Métodos de Agrupamento de Dados Simbólicos Baseados em funções de Dissimilaridades**. p. 147. Dissertação (Mestrado) - Universidade Federal de Pernambuco, Recife, 2008.

SILVA, L. F.; SEQUEIROS, G. O.; SANTOS, M. L. O.; FONTES, C; A; P.; MUCHALUAT-SAADE, D. C.; CONCI, A. Thermal Signal Analysis for Breast Cancer Risk Verification. **MEDINFO**, v. agosto, p. 746-750, 2015a.

SILVA, R. C. F.; HORTALE, V. A. Rastreamento do Câncer de Mama no Brasil: Quem , Como e Por quê? Breast cancer Screening in Brazil: Who , How and Why? **Revista Brasileira de Cancerologia**, v. 58, n. 1, p. 67–71, 2012.

SIM - **Sistema de Informações sobre Mortalidade**. BRASIL. Ministério da Saúde. Secretaria de Vigilância em Saúde. Departamento de Informática do SUS (Datasus). Disponível em: <<http://www2.datasus.gov.br/DATASUS/index.php?area=0205>>. Acesso em 07 de outubro de 2015

SOUZA, C. B.; ANDREÃO, R. V; SEGATTO, M. V. Processamento de sinais de ECG para geração automática de alarmes. **VI Workshop de Informática Médica**, p. 247–251, 2006.

TAN, T. Z; QUECK, C. NG, G. S.; NG, E. Y. K. A novel cognitive interpretation of breast cancer thermography with complementary learning fuzzy neural memory structure. **International Journal of Thermal Sciences**, v. 33, p. 652–666, 2007.

UDESC, U. **Câncer de mama**. 2007. Disponível em: <<http://www.joinville.udesc.br/processamentodeimagens/oCanc/oCanc.html>>.

VIANA, M. **Simulação do perfil de temperatura na mama através de geometria**

substituta obtida a partir de prótese mamária externa. p 118. Dissertação (Mestrado) — Universidade Federal de Pernambuco, Recife, 2010.

WANG, J.; CHANG, K.; CHEN, C.; CHIEN, K.; TSAI, Y. WU, Y.; TENG, Y; SHIH, T. T. Evaluation of the diagnostic performance of infrared imaging of the breast : a preliminary study. **Biomedical Engineering OnLine**, p. 1–14, 2010.

WEBB, A. R.; COPSEY, K. D. **Statistical pattern recognition**. 3 ed., Wiley, 2011.

ANEXOS

As figuras a seguir apresentam algumas documentações das pacientes utilizadas para realização dos exames termográficos:

Figura 53 – Ficha Anamnese (página frontal).

AMBULATÓRIO DE PATOLOGIA MAMÁRIA
D.M.I. - Disciplina de Ginecologia - Hospital das Clínicas

1. IDENTIFICAÇÃO

1.1 DATA: ☐☐☐ / ☐☐☐ / ☐☐☐ 1.3 REGISTRO: ☐☐☐☐☐☐☐ - ☐
1.2 NOME: _____ 1.4 IDADE: ☐☐
1.5 RAÇA ☐ 1.5.1 B ☐ 1.5.2 N ☐ 1.5.3 M 1.6 ESTADO CIVIL ☐ 1.6.1 C ☐ 1.6.2 S ☐ 1.6.3 V 1.7 SEXO ☐ 1.7.1 M ☐ 1.7.2 F

2. QP

☐ 2.1 DOR ☐ 2.2 SECREÇÃO ☐ 2.3 TU ☐ 2.4 HIPEREMIA ☐ 2.5 ECZEMA
☐ 2.6 ↑ VASCULAR ☐ 2.7 ↑ VOLUME ☐ 2.8 ABAULAMENTO ☐ 2.9 RETRAÇÕES ☐ 2.10 OUTROS: _____

3. LOCAL

☐ 3.1.A MD ☐ 3.2.A QSE ☐ 3.3.A QSI ☐ 3.4.A QII ☐ 3.5.A QIE ☐ 3.6.A JQE ☐ 3.7.A JQIT ☐ 3.8.A JQS ☐ 3.9.A JQIF ☐ 3.10.A RA
☐ 3.1.B ME ☐ 3.2.B QSE ☐ 3.3.B QSI ☐ 3.4.B QII ☐ 3.5.B QIE ☐ 3.6.B JQE ☐ 3.7.B JQIT ☐ 3.8.B JQS ☐ 3.9.B JQIF ☐ 3.10.B RA
☐ 3.1.C AMBAS

4. DURAÇÃO ☐☐ ANOS ☐☐☐ MESES ☐☐ DIAS

5. INTERROGATÓRIO SINTOMATOLÓGICO

☐ 5.1 MASTALGIA ☐ 5.1.1 CÍCLICA ☐ 5.1.2 ACÍCLICA ☐ 5.1.3 OUTRA
☐ 5.2 DESC. PAPILAR ☐ 5.2.1 ESPONTÂNEA ☐ 5.2.2 PROVOCADA ☐ 5.2.3 SEROSA ☐ 5.2.4 SANGÜINEA
☐ 5.2.5 BRANCA ☐ 5.2.6 PUS ☐ 5.2.7 VERDE ☐ 5.2.8 TRANSPARENTE
☐ 5.2.9 MONODUCTAL ☐ 5.2.10 POLIDUCTAL ☐ 5.2.11 UNILAT ☐ 5.2.12 BILATERAL

6. ANTECEDENTES FAMILIARES

☐ 6.1 DIABETES ☐ 6.2 HAS ☐ 6.3 CA ENDOMÉTRIO ☐ 6.4 CA OVÁRIO ☐ 6.5 CA MAMA ☐ 6.6 OUTRAS: _____

7. ANTECEDENTES PESSOAIS

☐ 6.7 DIABETES ☐ 6.8 HAS ☐ 6.9 CA ENDOMÉTRIO ☐ 6.10 CA OVÁRIO ☐ 6.11 CA MAMA
☐ 6.12 USO DE MEDICAMENTOS ☐ 6.13 CIRURGIA PRÉVIA ☐ 6.14 OUTRAS: _____

7. HÁBITOS ALIMENTARES

☐ 7.1 POBRE EM GORDURA ☐ 7.2 RICA EM GORDURA ☐ 7.3 SEM GORDURA

8. FATORES DE RISCO

DUM: _____ MENARCA: _____ CLIMATÉRIO: PRÉ ☐ PÓS ☐

☐ 8.1 CA MAMA 1º GRAU ☐ 8.2 CA MAMA 2º GRAU ☐ 8.3 NULIGESTA ☐ 8.4 STRESS
☐ 8.5 DIETA ↑ GORDURA ☐ 8.6 MENARCA PRECOCE ☐ 8.7 MENOPAUSA TARDIA ☐ 8.8 AO > 10 ANOS
☐ 8.9 TRH > 10 ANOS ☐ 8.10 CIR. MAMÁRIA PRÉVIA ☐ 8.11 CA MAMA ANTERIOR ☐ 8.12 TABAGISMO ()
☐ 8.13 ETILISMO ☐ 8.14 ABORTO ANTES DO 1º FILHO ☐ 8.15 NÃO AMAMENTOU G ____ P ____ A ____

9. EXAMES REALIZADOS

9.1 USG

☐ 9.1.1 NORMAL ☐ 9.1.2 SUSPEITO ☐ 9.1.3 BENIGNO ☐ 9.1.4 TÚ SÓLIDO ☐ 9.1.5 T. CÍSTICO ☐ 9.1.6 OUTRO: _____

LOCAL

☐ 9.1.A MD ☐ 9.1.A.1 QSE ☐ 9.1.A.2 QSI ☐ 9.1.A.3 QII ☐ 9.1.A.4 QIE ☐ 9.1.A.5 JQE ☐ 9.1.A.6 JQIT ☐ 9.1.A.7 JQS ☐ 9.1.A.8 JQIF ☐ 9.1.A.9 RA
☐ 9.1.B ME ☐ 9.1.B.1 QSE ☐ 9.1.B.2 QSI ☐ 9.1.B.3 QII ☐ 9.1.B.4 QIE ☐ 9.1.B.5 JQE ☐ 9.1.B.6 JQIT ☐ 9.1.B.7 JQS ☐ 9.1.B.8 JQIF ☐ 9.1.B.9 RA
Tamanho/ caract/ local: ☐☐☐☐ mm (,) ☐☐☐☐ mm (,) ☐☐☐☐ mm (,)

9.2 MAMOGRAFIA

☐ 9.2.1 NORMAL ☐ 9.2.2 DENS. ASSIMÉTRICA ☐ 9.2.3 NÓD. DELIMITADO ☐ 9.2.4 NÓD. PARCIAL//DEFINIDO
☐ 9.2.5 NÓD. IRRÉG ☐ 9.2.6 CALCIF. SUSPEITA ☐ 9.2.7 CALCIF. BENIGNA ☐ 9.2.8 EDEMA PELE
☐ 9.2.9 OUTROS


LOCAL:

☐ 9.2.A MD ☐ 9.2.A.1 QSE ☐ 9.2.A.2 QSI ☐ 9.2.A.3 QII ☐ 9.2.A.4 QIE ☐ 9.2.A.5 JQE ☐ 9.2.A.6 JQIT ☐ 9.2.A.7 JQS ☐ 9.2.A.8 JQIF ☐ 9.2.A.9 RA
☐ 9.2.B ME ☐ 9.2.B.1 QSE ☐ 9.2.B.2 QSI ☐ 9.2.B.3 QII ☐ 9.2.B.4 QIE ☐ 9.2.B.5 JQE ☐ 9.2.B.6 JQIT ☐ 9.2.B.7 JQS ☐ 9.2.B.8 JQIF ☐ 9.2.B.9 RA
Tamanho/ caract/ local: ☐☐☐☐ mm (,) ☐☐☐☐ mm (,) ☐☐☐☐ mm (,)

Figura 54 – Ficha Anamnese (página posterior).

EXAME FÍSICO

☒ NÓDULO SÓLIDO
☐ NÓDULO CÍSTICO
☒ NÓDULO IREGULAR
☒ ÁREA NODULAR



11.1 INSPEÇÃO ESTÁTICA

FORMA

☐ 11.1.1 CÔNICAS ☐ 11.1.2 FLÁCIDAS ☐ 11.1.3 SIMÉTRICAS ☐ 11.1.4 ASSIMÉTRICAS ☐ 11.1.5 PROPORCIONAIS
☐ 11.1.6 ↑ VOLUME ☐ 11.1.7 ↓ VOLUME ☐ 11.1.8 RETRAÇÃO MAMILAR ☐ 11.1.9 MAMA AXILAR

ALT. CULÂNEAS

☐ 11.1.10 NORMAIS ☐ 11.1.11 RETRAÇÃO DE PELE ☐ 11.1.12 ABAULAMENTO ☐ 11.1.13 PEAU D'ORANGE
☐ 11.1.14 ECZEMA CAM ☐ 11.1.15 ALT. VASCULAR ☐ 11.1.16 ORIFÍCIO FISTULOSO ☐ 11.1.17 HIPEREMIA

11.2 INSPEÇÃO DINÂMICA

☐ 11.2.1 NORMAL ☐ 11.2.2 RETRAÇÃO ☐ 11.2.3 ABAULAMENTOS ☐ 11.2.4 OUTROS: _____

11.3 PALPAÇÃO DE LINFONÓDOS

11.3.1 AXILA DIREITA

☐ 11.3.1.1 NORMAIS ☐ 11.3.1.2 ↑ VOLUME ☐ 11.3.1.3 ELÁSTICOS ☐ 11.3.1.4 DUROS ☐ 11.3.1.5 FIXOS ☐ 11.3.1.6 MÓVEIS
☐ 11.3.1.7 HOMOLAT. ☐ 11.3.1.8 CONTRA-LATER. ☐ 11.3.1.9 BILATER. ☐ 11.3.1.10 ADERIDOS ☐ 11.3.1.11 SUPRACLAV.

11.3.2 AXILA ESQUERDA

☐ 11.3.2.1 NORMAIS ☐ 11.3.2.2 ↑ VOLUME ☐ 11.3.2.3 ELÁSTICOS ☐ 11.3.2.4 DUROS ☐ 11.3.2.5 FIXOS ☐ 11.3.2.6 MÓVEIS
☐ 11.3.2.7 HOMOLAT. ☐ 11.3.2.8 CONTRA-LATER. ☐ 11.3.2.9 BILATER. ☐ 11.3.2.10 ADERIDOS ☐ 11.3.2.11 SUPRACLAV.

11.4 PALPAÇÃO DA MAMAS

11.4.1 MAMA DIREITA NORMAL

☐ 11.4.1.1 NODULARIDADE ☐ 11.4.1.2 TUMOR. ☐ 11.4.1.3 ELÁSTICO ☐ 11.4.1.4 FIXO PLANO SUPERFICIAL
☐ 11.4.1.5 FIXO PLANO PROFUNDO ☐ 11.4.1.6 SUP. REGULAR ☐ 11.4.1.7 SUP. IRREGULAR

☐ 11.4.1.8 QSI ☐ 11.4.1.9 QSE ☐ 11.4.1.10 QII ☐ 11.4.1.11 QIE
☐ 11.4.1.12 JQIT ☐ 11.4.1.13 JOE ☐ 11.4.1.14 JQS ☐ 11.4.1.15 JQIF ☐ 11.4.1.16 RRA

11.4.2 MAMA ESQUERDA NORMAL

☐ 11.4.2.1 NODULARIDADE ☐ 11.4.2.2 TUMOR. ☐ 11.4.2.3 ELÁSTICO ☐ 11.4.2.4 FIXO PLANO SUPERFICIAL
☐ 11.4.2.5 FIXO PLANO PROFUNDO ☐ 11.4.2.6 SUP. REGULAR ☐ 11.4.2.7 SUP. IRREGULAR

☐ 11.4.2.8 QSI ☐ 11.4.2.9 QSE ☐ 11.4.2.10 QII ☐ 11.4.2.11 QIE
☐ 11.4.2.12 JQIT ☐ 11.4.2.13 JOE ☐ 11.4.2.14 JQS ☐ 11.4.2.15 JQIF ☐ 11.4.2.16 RRA

13 HD: CID 1 ☐ ☐ ☐ _____ **CID 3** ☐ ☐ ☐ _____

CID 2 ☐ ☐ ☐ _____ **CID 4** ☐ ☐ ☐ _____

14 CONDUTA

☐ 14.1 ORIENTADA ☐ 14.2 MEDICADA ☐ 14.3 BIÓPSIA ☐ 14.4 PUNÇÃO ☐ 14.5 CIRURGIA

Figura 55 – Termo de consentimento livre e esclarecido.

TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

Título da Pesquisa: **USO DE IMAGENS TERMOGRÁFICAS PARA DIAGNÓSTICO MÉDICO.**

Pesquisador responsável:

Convidamos o(a) paciente _____ a participar deste estudo.

Objetivos da pesquisa: Avaliar o uso da Imagem por Termografia Infravermelha como uma ferramenta adicional no diagnóstico precoce de tumores de mama. Será usada uma câmera de infravermelho que se assemelha a uma filmadora digital.

Procedimentos: Os pacientes deverão repousar por 10 minutos no local do exame, onde será medida a temperatura do corpo através de termômetro clínico. Após os 10 minutos de aclimação, os participantes serão fotografados pela própria pesquisadora.

Local da Pesquisa: Os exames serão realizados no Hospital das Clínicas da Universidade Federal de Pernambuco.

Riscos: A pesquisa não apresenta riscos físicos ao participante, uma vez que não há contato com o paciente e não há emissão de radiação de forma alguma durante o exame. O exame é totalmente indolor.

Benefícios: Esta pesquisa, acompanhada de métodos já utilizados, pode criar novas esperanças na detecção prematura e precisa do câncer de mama.

Caráter confidencial: Toda a equipe da pesquisa se compromete a manter o caráter confidencial das informações obtidas.

Pedimos a sua colaboração, através desta autorização, para que o senhor(a) possa fazer parte de nossa pesquisa. Lembramos que o senhor(a) poderá desistir de participar, a qualquer instante, sem nenhum problema e que sua desistência não terá qualquer impedimento para a continuidade do seu tratamento clínico no Hospital das Clínicas da UFPE.

Eu, _____, identidade n° _____, abaixo assinado, declaro estar ciente dos principais objetivos, riscos e benefícios deste estudo e, tendo recebido as informações acima relacionadas, autorizo minha inclusão na pesquisa.

Recife, ____ de _____ de _____.

Participante

Pesquisador

Testemunha1

Testemunha2

