



Universidade Federal de Pernambuco  
Centro de Tecnologia e Geociências  
Departamento de Engenharia Mecânica  
Programa de Pós-Graduação em Engenharia Mecânica

Ramon de Lima Vila Nova

**USO DE IMAGENS TERMOGRÁFICAS DE MAMA PARA ANÁLISE DE  
PATOLOGIAS ATRAVÉS DA COMPARAÇÃO ENTRE DIVERSOS  
CLASSIFICADORES ESTATÍSTICOS**

Recife

2017

**RAMON DE LIMA VILA NOVA**

**USO DE IMAGENS TERMOGRÁFICAS DE MAMA PARA ANÁLISE DE  
PATOLOGIAS ATRAVÉS DA COMPARAÇÃO ENTRE DIVERSOS  
CLASSIFICADORES ESTATÍSTICOS**

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: Prof<sup>ª</sup>. Dr<sup>ª</sup>. Rita de Cássia Fernandes de Lima

Coorientador: Prof. Dr. Marcus Costa de Araújo

Recife

2017

Catálogo na fonte  
Bibliotecária Margareth Malta, CRB-4 / 1198

V695u Vila Nova, Ramon de Lima.  
Uso de imagens termográficas de mama para análise de patologias através da comparação entre diversos classificadores estatísticos / Ramon de Lima Vila Nova. - 2017.  
109 folhas, il., gráfs., tabs.

Orientadora: Profa. Dra. Rita de Cássia Fernandes de Lima.

Coorientador: Prof. Dr. Marcus Costa de Araújo.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Mecânica, 2017.

Inclui Referências.

1. Engenharia Mecânica. 2. Termografia. 3. Câncer de mama. 4. Processamento de imagens termográficas. 5. Dados intervalares. 6. Distância de Mahalanobis. 7. Classificação estatística. I. Lima, Rita de Cássia Fernandes de. (Orientadora). II. Araújo, Marcus Costa de. (Coorientador). III. Título.

UFPE

621 CDD (22. ed.)

BCTG/2017-329

1º de setembro de 2017

“USO DE IMAGENS TERMOGRÁFICAS DE MAMA PARA ANÁLISE DE  
PATOLOGIAS ATRAVÉS DA COMPARAÇÃO ENTRE DIVERSOS  
CLASSIFICADORES ESTATÍSTICOS”

RAMON DE LIMA VILA NOVA

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  
COORIENTADOR

---

Prof. Dr. CEZAR HENRIQUE GONZALEZ  
COORDENADOR DO PROGRAMA

BANCA EXAMINADORA:

---

Profª Drª RITA DE CÁSSIA FERNANDES DE LIMA (UFPE)

---

Prof. Dr. MARCUS COSTA DE ARAÚJO (UFPE)

---

Prof. Dr. DARLAN KARLO ELISIÁRIO DE CARVALHO (UFPE)

---

Profª Drª RENATA MARIA CARDOSO RODRIGUES DE SOUZA (UFPE)

## AGRADECIMENTOS

Agradeço primeiramente a Deus, que durante toda minha vida esteve ao meu lado me ajudando e fortalecendo nos momentos difíceis.

Agradeço aos meus pais, Waldir e Zislaine, que com muita paciência e amor me educaram e me proporcionaram momentos como este, sempre evidenciando que a educação e o conhecimento são a base para o sucesso profissional.

Agradeço aos meus irmãos Diego e Larissa, pelo apoio e companheirismo que me proporcionaram.

Agradeço aos meus avós, Zumba e Adautina, *in memoriam*, que tanto me amaram e me motivaram a crescer na vida por meio do conhecimento e da formação acadêmica.

Agradeço à minha orientadora, professora Rita, que depositou confiança em mim, me incentivou e me direcionou de como eu deveria agir para desenvolver um bom trabalho.

Agradeço ao meu coorientador, Marcus, que com toda paciência e humildade me passou o seu conhecimento para que eu desenvolvesse um bom trabalho.

Agradeço aos meus amigos e irmãos da igreja, por todo o apoio, incentivo e orações que me deram forças para a conclusão deste projeto.

Agradeço aos companheiros do LABTERMO, pelos conhecimentos repassados e por todo o companheirismo durante o projeto.

Agradeço a CAPES pelo apoio financeiro para execução deste trabalho.

*Bendito o homem que confia no SENHOR e cuja esperança é o SENHOR*

*(Jeremias 17:7)*

## RESUMO

A técnica de inspeção através de imagens termográficas tem se mostrado um procedimento promissor com respeito ao diagnóstico precoce de anomalias mamárias. A termografia é um exame simples, indolor, não-invasivo, que não usa radiação ionizante e é de baixo custo. Cisto e tumores apresentam uma elevada atividade metabólica provocando variações de temperaturas nestas regiões que podem ser detectados através de uma avaliação adequada de termogramas. A detecção do tipo de anomalia é realizada por meio de uma análise das suas características e as anomalias podem ser avaliadas e separadas em classe com o auxílio de classificadores estatísticos. O presente trabalho tem como objetivo utilizar métodos de classificação de imagens termográficas. Para isso, são apresentadas duas propostas de classificação de imagens digitais. A primeira proposta consiste em utilizar um classificador de quatro classes (Maligno, Benigno, Cisto e Normal), baseado na distância mínima de Mahalanobis para dados intervalares. A segunda proposta consiste em realizar a combinação de classificadores com o objetivo de se obter melhores resultados de classificação para anomalias mamárias, dando ênfase à taxa de acerto (ou acurácia) e à sensibilidade à Classe Maligno. A primeira abordagem de classificação obteve 72,71% de taxa de acerto e 96,30% de sensibilidade à Classe Maligno. A segunda abordagem, que consiste na combinação de classificadores, obteve 71,15% de taxa de acerto e 87,18% de sensibilidade à Classe Maligno, para um classificador multiclasse (Maligno, Benigno, Cisto e Normal), enquanto que, para um classificador binário (Câncer e Não-Câncer), os resultados obtidos com a combinação de classificadores foram de 94,21% de taxa de acerto do classificador e 95,26% de sensibilidade à Classe Maligno.

**Palavras-chave:** Termografia. Câncer de mama. Processamento de imagens termográficas. Dados intervalares. Distância de Mahalanobis. Classificação estatística.

## ABSTRACT

The technique of inspection of infrared images has been shown to be a promising procedure for the early diagnosis of breast abnormalities. Thermography is a simple examination, painless, non-invasive, that does not use ionizing radiation, and it is a low cost examination. Cyst and tumors have a high metabolic activity causing temperature variations in those regions that can be detected by an accurate evaluation of the breast thermograms. The detection of the specific breast disorder is performed by means of a statistical analysis of the selected characteristics. The abnormalities are evaluated and separated in classes with the aid of statistical classifiers. The present work aims to use methods of classifying infrared breast images. Two types of classifications are proposed. The first proposal used a classifier considering four classes (Malignant, Benign, Cyst and Normal), based on the minimum distance of Mahalanobis for interval data. The second proposal performed the combination of classifiers in order to obtain better classification results for breast abnormalities. The first classification approach obtained 72,71% of accuracy and 96,30% of sensitivity to the Malignant Class. The second approach, consisting of the combination of classifiers, obtained 71,15% of accuracy and 87,18% of sensitivity to the Malignant Class for a multiclass classifier (Malignant, Benign, Cyst and Normal). Considering a binary classifier (Cancer and Non-Cancer), the results obtained with the combination of classifiers were 94,21% of accuracy and 95,26% of sensitivity to the Malignant Class.

**Keywords:** Thermography. Breast cancer. Infrared images processing. Interval data. Mahalanobis distance. Classification.

## LISTA DE ILUSTRAÇÕES

Figura 1 – Contribuição dos principais fatores causadores de mortes por câncer no mundo, nos países de alta renda e nos países de baixa e média renda .....	16
Figura 2 – Procedimento de segmentação proposto por Motta (2010) .....	28
Figura 3 – Segmentação desenvolvida por Araújo (2014) .....	29
Figura 4 – Imagem Segmentada pelo método de Dourado Neto (2014).....	29
Figura 5 – Espectro de ondas eletromagnéticas.....	34
Figura 6 – Processo de geração de imagem termográfica .....	36
Figura 7 – Processo de classificação de imagens .....	40
Figura 8 – Gráfico do pareto-ótimo.....	45
Figura 9 – Espaço das soluções no espaço das funções-objetivo .....	46
Figura 10 – Esquemas do procedimento de otimização multiobjetivo.....	48
Figura 11 – Criação de um <i>cromossomo</i> em Algoritmos Genéticos .....	51
Figura 12 – Etapas de um Algoritmo Genético .....	53
Figura 13 – Arquiteturas de combinação de classificadores .....	54
Figura 14 – Modelo de combinação de classificadores <i>Stacking</i> .....	57
Figura 15 – Interface da função de otimização multiobjetivo no Matlab.....	58
Figura 16 – Fluxograma das etapas de classificação e otimização.....	61
Figura 17 – Aparato Mecânico .....	62
Figura 18 – Matriz de temperaturas exportada do <i>software FLIR QuickReport</i> .....	64
Figura 19 – Imagem colorida correspondente aos valores da matriz de temperatura .....	65
Figura 20 – Máscara criada sobre a região delimitada .....	65
Figura 21 – Imagem das regiões segmentadas das mamas esquerda e direita .....	65
Figura 22 – Representação gráfica dos intervalos de temperatura das matrizes segmentadas das mamas direita e esquerda e de suas respectivas matrizes morfológicas .....	67
Figura 23 – Fluxograma do processo de otimização dos parâmetros de peso $\lambda_k$ .....	70

Figura 24 – Representação gráfica de algumas características definidas a partir das temperaturas máximas e mínimas da mama esquerda e da mama direita .....	74
Figura 25 – Matriz de confusão da classificação utilizando o classificador de Araújo (2014) ampliado para quatro classes, com a seguinte combinação dos parâmetros de peso $\lambda_k$ : $\lambda_1 = 0,3$ ; $\lambda_2 = 0,2$ ; $\lambda_3 = 0,6$ ; $\lambda_4 = 0,6$ .....	80
Figura 26 – Gráfico de pareto-ótimo das funções objetivo Taxa de acerto e Sensibilidade à Classe Maligno .....	85
Figura 27 – Matrizes de confusão da classificação multiclasse através do WEKA .....	89
Figura 28 – Matriz de Confusão da classificação da base de Vasconcelos (2017) para o classificador SMO .....	92
Figura 29 – Matrizes de confusão da classificação multiclasse combinando classificadores através do WEKA .....	94
Figura 30 – Matrizes de confusão da classificação binária combinando classificadores através do WEKA.....	96

## LISTA DE TABELAS

Tabela 1 – Incidência do câncer de mama de acordo com a faixa etária média.....	24
Tabela 2 – Matriz de Confusão .....	42
Tabela 3 – Interpretação do coeficiente Kappa .....	43
Tabela 4 – Base de dados para a classificação .....	63
Tabela 5 – Resultado de classificação com a base contendo 87 imagens utilizando o classificador de Araújo (2014) ampliado para quatro classes .....	79
Tabela 6 – Combinações dos parâmetros de peso $\lambda_k$ que alcançaram os melhores resultados de classificação, utilizando o classificador proposto por Araújo (2014), ampliado para quatro classes .....	79
Tabela 7 – Resultado de classificação com a base contendo 71 imagens utilizando o classificador de Araújo (2014) em sua forma original contendo três classes.....	81
Tabela 8 – Combinações dos parâmetros de peso $\lambda_k$ que alcançaram os melhores resultados de classificação, utilizando o classificador de Araújo (2014) em sua forma original para três classes, com uma base de 71 imagens .....	81
Tabela 9 – Valores do procedimento de otimização multiobjetivo apresentando as melhores combinações dos parâmetros de peso $\lambda_k$ .....	84
Tabela 10 – Melhor combinação dos parâmetros de peso $\lambda_k$ , encontrados por meio do processo de otimização e do EPG.....	86
Tabela 11 – Resultado da classificação baseado na combinação dos parâmetros de peso $\lambda_k$ encontrados por meio da otimização .....	86
Tabela 12 – Resultados da classificação multiclasse utilizando classificadores do WEKA .....	88
Tabela 13 – Comparação dos processos de classificação.....	90
Tabela 14 – Quantidade de imagens para quatro classes.....	91
Tabela 15 – Quantidade de imagens para duas classes .....	91
Tabela 16 – Resultados da classificação multiclasse através do WEKA .....	92
Tabela 17 – Resultados da classificação multiclasse combinando classificadores através do WEKA .....	93
Tabela 18 – Comparação dos resultados da classificação multiclasse SMO e <i>Voting</i> ....	94

Tabela 19 – Resultados da classificação binária através do WEKA .....	95
Tabela 20 – Resultados da classificação binária combinando classificadores através do WEKA .....	96
Tabela 21 – Comparação entre resultados da classificação binária usando SMO e <i>Voting</i> .....	97
Tabela 22 – Síntese dos resultados de classificação de imagens termográficas mamárias de trabalhos desenvolvidos no grupo de pesquisa do DEMEC/UFPE .....	98

## LISTA DE SÍMBOLOS

B	Constante de Stefan-Boltzmann
c	Velocidade da luz
°C	Graus celsius
$FN_i$	Falso negativo para i-ésima classe
$FP_i$	Falso positivo para i-ésima classe
$k$	Kernel
K	Kelvin
MD	Matriz de temperaturas da mama Direita
ME	Matriz de temperaturas da mama esquerda
$M_{MD}$	Matriz morfológica da mama direita
$M_{ME}$	Matriz morfológica da mama esquerda
$R_a^2$	Coefficiente de determinação ajustado
T	Temperatura
$VN_i$	Verdadeiro negativo para i-ésima classe
$VP_i$	Verdadeiro positivo para i-ésima classe
W	Poder emissivo de um corpo a uma temperatura T
$\lambda$	Comprimento de onda
$\lambda_k$	Parâmetro de peso de cada limite do intervalo <i>Inf</i> e <i>Sup</i> na definição da matriz de covariância parametrizada para cada classe
$\varepsilon$	Emissividade
v	Frequência

## LISTA DE ABREVIATURAS E SIGLAS

AG	Algoritmo Genético
ATM	Articulação Temporomandibular
DORT	Doença Ocupacional Relacionada ao Trabalho
DT	Árvores de Decisão
DTM	Disfunção da Articulação Temporomandibular
EPG	Erro Percentual Global
ES	Elemento Estruturante
HC	Hospital das Clínicas
IBK	Instance Based Learner
ILT	Incremento Localizado de Temperatura
INCA	Instituto Nacional do Câncer
KNN	K-Nearest Neighbours
Matlab	Matrix Laboratory
MLP	Multilayer Perceptron
MSC	Multiple System Classifiers
RNA	Rede Neural Artificial
ROC	Receiver Operating Characteristic
ROI	Region of Interest
SARS	Síndrome Respiratória Aguda Grave
SMO	Sequential Minimal Optimization
SVM	Support Vector Machine
TCLE	Termo de Consentimento Livre e Esclarecido
WEKA	Waikato Environment for Knowledge Analysis

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	15
<b>1.1</b>	<b>Motivação</b> .....	15
<b>1.2</b>	<b>Objetivos</b> .....	19
1.2.1	Objetivo geral .....	19
1.2.2	Objetivos específicos.....	19
<b>1.3</b>	<b>Organização do trabalho</b> .....	20
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b> .....	21
<b>2.1</b>	<b>Termografia na área médica</b> .....	21
<b>2.2</b>	<b>Termografia no diagnóstico ao câncer de mama</b> .....	24
<b>2.3</b>	<b>Segmentação</b> .....	28
<b>2.4</b>	<b>Sistema de Múltiplo Classificadores</b> .....	30
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b> .....	32
<b>3.1</b>	<b>Termografia</b> .....	32
<b>3.2</b>	<b>Processamento da imagem termográfica</b> .....	37
<b>3.3</b>	<b>Segmentação</b> .....	37
<b>3.4</b>	<b>Extração de Características</b> .....	38
<b>3.5</b>	<b>Classificação de imagens termográficas digitais</b> .....	39
<b>3.6</b>	<b>Sensibilidade, Especificidade e Matriz de Confusão</b> .....	41
<b>3.7</b>	<b>Coefficiente Kappa</b> .....	43
<b>3.8</b>	<b>Otimização</b> .....	43
<b>3.9</b>	<b>Erro Percentual Global (EPG)</b> .....	49
<b>3.10</b>	<b>Algoritmos Genéticos (AG)</b> .....	50
<b>3.11</b>	<b>Combinação de Classificadores</b> .....	53
<b>3.12</b>	<b>Plataformas computacionais</b> .....	57
3.12.1	MATLAB .....	57
3.12.2	Minitab .....	59
3.12.3	WEKA .....	59
<b>4</b>	<b>METODOLOGIA</b> .....	60
<b>4.1</b>	<b>Metodologia 1</b> .....	60
4.1.1	Aquisição das imagens termográficas .....	61
4.1.2	Base de dados .....	63
4.1.3	Segmentação.....	63
4.1.4	Extração de Características .....	66
4.1.5	Classificação das imagens termográficas .....	68
4.1.6	Definição dos parâmetros $\lambda_k$ através da otimização .....	70
<b>4.2</b>	<b>Metodologia 2</b> .....	73
<b>4.3</b>	<b>Metodologia 3</b> .....	76
<b>5</b>	<b>RESULTADOS E DISCUSSÃO</b> .....	78
<b>5.1</b>	<b>Resultados obtidos com a Metodologia 1</b> .....	78
5.1.1	Otimização do classificador para encontrar os parâmetros de peso $\lambda_k$ .....	81
<b>5.2</b>	<b>Resultados obtidos com a Metodologia 2</b> .....	88
<b>5.3</b>	<b>Resultados obtidos com a Metodologia 3</b> .....	91
<b>5.4</b>	<b>Síntese dos resultados</b> .....	97
<b>6</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS</b> .....	99
	<b>REFERÊNCIAS</b> .....	101

# 1 INTRODUÇÃO

## 1.1 Motivação

A evolução científica e tecnológica dos últimos tempos tem conduzido à introdução de novos dispositivos e procedimentos nos diagnósticos médicos. A engenharia tem um importante papel nessa modernização, servindo de base de estudo para o desenvolvimento de novas técnicas medicinais. Através destas novas abordagens, detecção de doenças em pacientes diversos tem se evidenciado cada vez mais precocemente, facilitando o tratamento e aumentando as chances de cura. Dentre exemplos de aplicações da engenharia na medicina, pode-se citar: projeto de próteses, a biotecnologia, com o desenvolvimento da engenharia genética, aplicação da nanotecnologia na confecção de tecidos sintéticos não rejeitados pelo organismo, o projeto de novas técnicas e equipamentos ligados ao desenvolvimento de formas de diagnósticos, o processamento de imagens médicas, entre outros.

A utilização de conhecimentos científicos e tecnológicos na medicina é fortemente baseada em técnicas matemáticas, estatísticas e computacionais, tendo por objetivo a minimização de imprecisões e incertezas, qualificando o procedimento utilizado. Uma área da medicina que vem evoluindo com a utilização dessas técnicas de diagnóstico é a detecção do câncer de mama.

O câncer é o nome dado a um grupo de doenças que têm em comum a proliferação celular excessiva e descontrolada, que persiste mesmo que tenha cessado o estímulo inicial que a causou. Qualquer tipo de célula tem potencial de perder o controle e originar um câncer, também chamado de neoplasia (MALZYNER & CAPONERO, 2013).

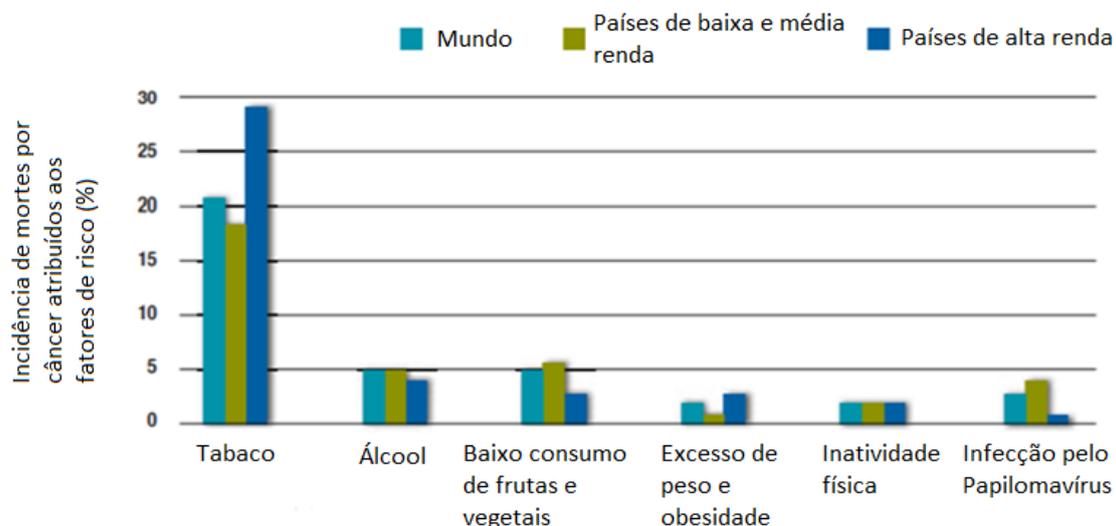
Uma das principais causas do câncer são as modificações genéticas adquiridas por fatores externos. Essas modificações são, principalmente, devido às mutações do DNA das células somáticas que se propagam por um tipo de divisão celular denominado mitose. Os genes que promovem tal divisão estão ativos na célula embrionária, mas inativos nas células adultas. Porém, se sofrerem alguma mudança, que possa ativá-los em momentos inadequados, eles se transformam em oncogenes e provocam o câncer (PRADO, 2014).

As células cancerosas diferem das normais pela perda de controle sobre a divisão celular. Enquanto as células normais dividem-se somente quando expostas a influência extracelular (fatores de crescimento e hormônios, por exemplo), as células cancerosas não respondem a esses controles, e dividem-se continuamente, formando tumores (grandes massas de células). Os tumores podem ser de origem maligna ou de origem benigna. Outra diferença entre células cancerosas e normais consiste na capacidade de as células cancerosas invadirem os tecidos vizinhos e propagar-se para outras partes do corpo, num processo chamado de metástase (PRADO, 2014).

A etiologia do câncer ainda é desconhecida, mas, de acordo com Jurberg *et al.* (2006) e Maruyama *et al.* (2006), a população, de modo geral, está muito exposta aos

fatores de risco que podem gerar câncer, tais como: tabaco, álcool, dieta rica em gordura e pobre em frutas e vegetais, vida sedentária, alguns vírus como o da hepatite B e fatores genéticos. Como pode ser observado na Figura 1, o grande responsável pelo desenvolvimento do câncer é o uso de tabacos.

Figura 1 – Contribuição dos principais fatores causadores de mortes por câncer no mundo, nos países de alta renda e nos países de baixa e média renda.



Fonte: adaptado de DANAEI *et al.* (2005)

O câncer de mama está entre os tipos de câncer de maior incidência nas mulheres no Brasil e no mundo, ocupando a segunda posição e atrás apenas do câncer de pele não melanoma, representando um total de 25% dos casos de cânceres nas mulheres. Segundo o Instituto Nacional do Câncer, INCA, o câncer já causou o óbito de 14000 pacientes desde 2013, e para o ano de 2017, são esperados, no Brasil, cerca de 57000 novos casos da doença (INCA, 2016). Se detectados precocemente, com um tamanho de tumor menor do que 10 mm, as pacientes com câncer de mama têm 85% de chance de serem curadas, enquanto que se descoberto tardiamente, as chances de cura do câncer de mama, nas pacientes, caem para 10% (QI & DIAKIDES, 2003). Uma detecção tardia do câncer de mama pode ser considerada quando o câncer é identificado em um estágio bem avançado da doença, podendo provocar metástase, de modo que as intervenções médicas para a cura do câncer pouco podem fazer para reverter o quadro clínico das pacientes.

Entre os métodos para detecção do câncer de mama, os mais comuns são: o exame clínico, que tem baixo custo, a ultrassonografia e a mamografia, que é considerado o principal exame utilizado para o diagnóstico em estágios iniciais do câncer de mama (INCA, 2012 apud RESMINI *et al.*, 2012). Segundo o autor, a mamografia apresenta uma alta sensibilidade ao diagnóstico do câncer quando o exame é realizado em pacientes de mais idade. Tais pacientes, que já passaram pelo período da menopausa, apresentam a

estrutura mamária formada por maior quantidade de tecido adiposo, o que gera bons contrastes aos feixes de Raios-X de baixa dosagem emitidos no exame, gerando bons resultados quanto à sensibilidade. Porém, em pacientes jovens, este exame não apresenta resultados muito confiáveis, já que a mama destas pacientes é constituída, principalmente, por tecido glandular, mais denso, o que gera dificuldades na identificação e interpretação diferencial entre os tecidos e os achados relevantes pela mamografia (KOAY *et al.*, 2004). Enquanto que para mulheres mais velhas, com idade entre 60 e 70 anos, a mamografia atinge 85% de sensibilidade, para mulheres mais jovens esse valor cai para 64%, o que evidencia a relação direta entre a idade das pacientes e a sensibilidade do exame (QI & DIAKIDES, 2003). Além disso, a mamografia é considerada um exame que pode ser prejudicial para as pacientes, pois os Raios-X podem causar lesões nos tecidos por eles penetrados. Cada vez que a mama de uma paciente pré-menopausa é exposta aos Raios-X emitidos num exame de mamografia, há aumento do risco de essa paciente desenvolver câncer de mama em 2%, portanto, uma exposição a 35 exames de mamografia dobraria as chances de a paciente desenvolver câncer de mama (ARABI, MUTTAN & SUJI, 2010 apud RESMINI *et al.*, 2012). Portanto, devido a essa agressividade da mamografia juntamente com a motivação de se detectar mais precocemente o câncer de mama, novas técnicas de diagnóstico do câncer de mama estão sendo analisadas e desenvolvidas com o objetivo de alcançar resultados mais precisos. Nesse contexto, a termografia pode ter um papel importante no diagnóstico precoce destas pacientes jovens com mamas densas (SCHAEFER *et al.*, 2009).

A técnica de utilização de imagens termográficas se apresenta como uma ferramenta promissora no auxílio à detecção do câncer de mama. Deste modo, estudos vêm sendo realizados para viabilizar a utilização da termografia como um dos exames para detecção do câncer de mama. Termografia é um método simples, rápido, de baixo custo, sem contato com o paciente, indolor e não-invasivo e que este não usa radiação ionizante, que vem sendo utilizado na área médica. Ele captura imagens, denominadas termogramas, por meio da radiação infravermelha emitida pelo corpo gerando informações a respeito da distribuição de temperatura de uma superfície. Os termogramas por si só são insuficientes para o médico fazer um diagnóstico, portanto ferramentas analíticas como os métodos bioestatísticos ou redes neurais artificiais devem ser utilizadas (NG & KEE, 2007).

A termografia tem uma grande vantagem em relação aos demais métodos convenientes de diagnósticos de câncer de mama. Alguns autores afirmam que a técnica tem a capacidade de detectar sinais precoces de câncer de mama em até 10 anos antes de qualquer outra modalidade de imagem (HEAD *et al.*, 2000 apud MOGHBEL & MASHOHOR, 2011). A eficiência na detecção precoce do câncer de mama juntamente com o desenvolvimento tecnológico, com equipamentos com maiores qualidades na resolução de imagens, trouxe de volta à tona o interesse pelo desenvolvimento da termografia na área médica. Essa característica coloca a termografia como uma importante ferramenta do diagnóstico do câncer de mama, complementando a mamografia tradicional. A mamografia quando aplicada em pacientes com exames

clínicos suspeitos, a sensibilidade é de 83%, a combinação da mamografia com a termografia aumenta a sensibilidade para 93%, e quando os três modos (o exame clínico, a mamografia e a termografia) são considerados em conjunto, a sensibilidade alcança 98%, reforçando a ideia de que tanto a termografia quanto a mamografia podem ser complementares entre si. Quando combinadas, cada uma pode neutralizar as deficiências da outra (NG & SUDHARSAN, 2001).

As imagens termográficas são analisadas e processadas por meio de técnicas de aprendizagem de máquinas com o auxílio de ferramentas computacionais. Para isso, são desenvolvidas ferramentas que são “ensinadas e treinadas” a separar as imagens em classes baseado nas suas características, num procedimento chamado de classificação de imagens termográficas.

Araújo (2014) desenvolveu um classificador de imagens termográficas de anomalias mamárias. Em seu projeto, o autor classifica as imagens em três classes (Maligno, Cisto e Benigno) de acordo com suas características. O procedimento de classificação desenvolvido é baseado na distância mínima para dados intervalares das mamas. O critério de escolha do classificador é baseado na distância de Mahalanobis parametrizada. Esta distância é definida através da matriz de covariância comum entre *Inf* e *Sup*, que serão compreendidos posteriormente. As matrizes de covariância comum são parametrizadas para cada classe  $C_k$  do algoritmo de classificação. Portanto, é definido um parâmetro de controle  $\lambda_k \in [0,1]$  para cada classe  $C_k$  que corresponde ao peso dado a cada limite do intervalo *Inf* e *Sup* na definição da matriz de covariância parametrizada de cada classe. Desse modo, este parâmetro  $\lambda_k$  tem uma influência direta na acurácia do classificador, e procedimentos iterativos são realizados para encontrar a melhor combinação desses parâmetros.

Durante o desenvolvimento desta dissertação, será proposta a inclusão de uma nova classe (Classe Normal) para este classificador estatístico, e será realizado um estudo analisando a melhor combinação destes parâmetros de peso  $\lambda_k$ . O objetivo de se incluir a Classe Normal partiu da ideia de tornar o classificador mais completo, podendo ser utilizado para quaisquer pacientes, tanto aquelas que apresentam algum tipo de patologia quanto para as pacientes cujas mamas são saudáveis. A proposta é fornecer subsídios confiáveis para que a termografia possa ser utilizada como uma ferramenta de triagem para o diagnóstico do câncer de mama. Neste caso, é necessário se utilizar um classificador que contenha todas as classes possíveis de diagnóstico. Assim, a Classe Normal deve ser incluída no classificador estatístico, tornando o exame mais abrangente e aplicável para qualquer tipo de mama.

O presente trabalho faz parte do seguinte projeto de pesquisa: **“Análise de viabilidade do uso de câmera termográfica como ferramenta auxiliar no diagnóstico de câncer de mama em hospital público localizado em clima tropical”**. A pesquisa foi aprovada pelo Comitê de Ética da Universidade Federal de Pernambuco (UFPE) – Brasil, com registro no Ministério da Saúde sob o número CEP/CCS/UFPE N°279/05. O projeto foi iniciado em 2005 e, desde então, realiza estudos da termografia no diagnóstico do

câncer de mama em pacientes com idade acima de 35 anos com objetivo de viabilizar tal procedimento. Devido ao aumento de casos de câncer de mama em pacientes jovens, esse estudo foi estendido também para pacientes abaixo dos 35 anos de idade. Todas as pacientes analisadas são voluntárias e fazem parte do Ambulatório de Mastologia da Clínica Ginecológica do Departamento Materno-Infantil do Hospital das Clínicas da UFPE.

## 1.2 Objetivos

### 1.2.1 Objetivo geral

O objetivo geral do presente trabalho é desenvolver melhorias em um método de classificação estatística de imagens termográficas baseado em variáveis intervalares para que, assim, possa ser aplicado como ferramenta mais eficaz no auxílio da detecção precoce do câncer de mama. As mamas serão classificadas em quatro classes, três classes considerando as suas anormalidades (cisto/ malignas/ benignas) e uma Classe Normal.

### 1.2.2 Objetivos específicos

Como objetivos específicos, pode-se citar:

- Ampliar o número de classes do classificador desenvolvido por Araújo (2014) de três classes (Maligno, Benigno e Cisto) para quatro classes (Maligno, Benigno, Cisto e Normal);
- Otimizar o processo de classificação, desenvolvendo uma metodologia para estimar a melhor combinação dos parâmetros  $\lambda_k$  da distância de Mahalanobis correspondente a cada classe  $C_k$ , proposto em Araújo *et al.* (2016), que apresente os melhores valores de sensibilidade e de porcentagem de acerto para o classificador;
- Comparar os resultados obtidos pela metodologia que propõe a ampliação e a otimização do classificador desenvolvido por Araújo (2014), utilizando a segmentação manual, com os resultados de classificação que utiliza o procedimento de segmentação automática, desenvolvido por Dourado Neto (2014), e classificadores do WEKA;
- Apresentar uma proposta de combinação dos melhores classificadores propostos por Vasconcelos (2017) para classificação de anomalias mamárias, com o objetivo de se obter um melhor valor de taxa de acerto e de sensibilidade à classe Maligno.

### 1.3 Organização do trabalho

O presente trabalho será organizado em 6 capítulos. Este capítulo introdutório apresentou informações básicas sobre o câncer, em especial o câncer de mama. Foi apresentado como surgem os tumores bem como os fatores de risco que contribuem para a sua formação. Foi citada a importância do seu diagnóstico precoce, além de citar a termografia como uma nova técnica para auxiliar no diagnóstico do câncer de mama.

No Capítulo 2, a revisão bibliográfica apresentará uma breve descrição sobre o uso e a aplicação da termografia na área médica, bem como sua evolução, com observações de estudos de classificadores de imagens termográficas de mamas. Será apresentada uma breve revisão dos resultados de pesquisadores quanto à eficiência da termografia no auxílio ao diagnóstico do câncer de mama.

No Capítulo 3, será apresentada uma fundamentação teórica apresentando conceitos e princípios físicos da termografia. Será visto como ocorre o processo de aquisição e processamento das imagens por infravermelho, mostrando a importância da segmentação e da extração de características no procedimento de classificação. Posteriormente, será abordado o conceito de otimização, apresentando seu funcionamento e importância. Finalizando o capítulo, será visto como ocorre o processo de combinação de classificadores.

No Capítulo 4, serão apresentadas três metodologias. Em uma metodologia será apresentada a aplicação da otimização num processo de classificação, evidenciando os benefícios que esta técnica pode trazer quanto a um processamento mais rápido da classificação. Uma segunda metodologia será apresentada utilizando um procedimento de segmentação automática para que os resultados possam ser comparados aos resultados apresentados na primeira metodologia. Finalmente, a terceira e última metodologia apresenta uma abordagem de combinação de classificadores, sugerindo que esta técnica pode apresentar resultados mais satisfatórios do que os resultados obtidos pelos classificadores individualmente.

No Capítulo 5, serão analisados os resultados obtidos por meio das abordagens apresentadas nas três metodologias citadas, e avaliado se as metodologias propostas alcançam resultados satisfatórios para modelos de classificação de imagens termográficas e analisando a viabilidade de tais técnicas para o diagnóstico de anomalias mamárias.

Finalizando a dissertação, no Capítulo 6, serão apresentadas conclusões e considerações finais a respeito do estudo realizado. Serão apresentadas, também, sugestões para trabalhos futuros para que, assim, possa-se desenvolver novas abordagens voltadas para classificadores estatísticos com o objetivo de se obter melhores resultados e, desse modo, se consolide cada vez mais a técnica da termografia na área médica.

## 2 REVISÃO BIBLIOGRÁFICA

### 2.1 Termografia na área médica

Como efeito natural do metabolismo, o ser humano libera constantemente diferentes níveis de energia no comprimento de onda na faixa do infravermelho e esta informação pode ser expressa e medida na forma de calor (CORTE & HERNANDEZ, 2016).

O ser humano tem a capacidade de manter a temperatura do corpo constante, independente do meio ambiente. A temperatura do corpo é preservada dentro de um limite, no intervalo de aproximadamente 33 a 42 °C, temperatura esta desejável para o melhor funcionamento do corpo humano. Se numa determinada região o corpo apresenta uma certa variação de temperatura de alguns graus, pode ser um possível indicativo de alguma doença. O corpo humano controla sua temperatura por um processo fisiológico chamado termorregulação (LAHIRI *et al.*, 2012).

A primeira observação da relação entre a temperatura de uma região do corpo e alguma anomalia nesta região se deu por volta de 400 a.C., quando Hipócrates observou a distribuição de calor num corpo colocando uma espécie de uma lama sobre uma determinada região do abdômen deste corpo e observando que algumas áreas secavam mais rápido que outras, concluindo que ali encontrava-se uma determinada região com uma temperatura mais elevada comparada com as temperaturas das regiões vizinhas, podendo representar alguma anomalia (RING, 2004).

Em 1595, Galileu Galilei criou o primeiro objeto que relacionava a temperatura numa determinada escala, o qual foi denominado termoscópio. Em 1868, Carl Wunderlich contribuiu para um grande progresso na medicina desenvolvendo um termômetro clínico registrando a progressão da temperatura em um grande número de pacientes doentes, fazendo um registro gráfico térmico para cada paciente (RING, 2004). Carl Wunderlich fez um estudo sistemático comparando a temperatura de indivíduos com febre com pessoas saudáveis, e assim indicou que uma faixa de temperatura entre 36,3 °C e 37,5 °C pode ser considerada normal, e temperaturas fora desse intervalo podem ser um indicativo de uma possível doença (LAHIRI *et al.*, 2012).

A descoberta da radiação infravermelha se deu por volta de 1800 quando Sir Herschel fez a primeira gravação de uma imagem térmica junto ao seu filho, abrindo uma nova dimensão no campo da medição da temperatura. Em 1934, Hardy realizou um estudo descrevendo o papel fisiológico da emissão infravermelha propondo que a pele humana pode ser considerada como um corpo negro de radiação. Além de estabelecer a importância dos valores da temperatura obtidos por técnicas infravermelhas para o diagnóstico de doenças (LAHIRI *et al.*, 2012).

Harzbecker *et al.* (1978) já apontavam, em seus estudos, a termografia como uma técnica promissora, capaz de medir a energia térmica corporal, sem contato, de forma rápida e dinâmica, gerando imagens termográficas. Em seu trabalho, determinaram que processos funcionais e fisiopatológicos apresentam mudanças de temperatura, de modo que, o uso da termografia poderia ser recomendado para o diagnóstico de doenças, mapeando a distribuição de temperatura da superfície corporal (MEIRA *et al.*, 2014).

Problemas com baixa sensibilidade dos detectores e com limitações técnicas representavam uma grande quantidade de erros para a termografia, fazendo com que a técnica termográfica tivesse uma limitada aceitação até meados dos anos 90. A partir de então, houve uma grande evolução nos equipamentos para aquisição de imagens termográficas, com sofisticadas câmeras acopladas a computadores com programas específicos de modo que as imagens podem ser processadas com obtenções de informações confiáveis. As imagens arquivadas apresentam boa qualidade, tornando a termografia um método de diagnóstico seguro e preciso (MEIRA *et al.*, 2014).

Atualmente, a aquisição destas imagens por infravermelho é feita por meio de uma câmera, com sensibilidade na faixa do infravermelho, que fornece uma imagem da distribuição de temperatura da superfície do corpo analisado ou em partes dele. Para isso, as câmeras termográficas utilizam um sensor com resposta na faixa do infravermelho para converter em sinais elétricos a radiação térmica emitida pela superfície da pele. Estes sinais elétricos são tratados e digitalizados, para, em seguida, serem quantificados em uma escala adequada de níveis de cinza ou pseudo-cores (com o objetivo de se obter uma imagem colorida) e apresentados na forma de uma imagem médica digital (SANCHES, 2009).

Niehof *et al.* (2007) desenvolveram um estudo avaliando a sensibilidade, a especificidade, a confiabilidade e a repetitividade na avaliação de imagens termográficas. Foi analisada a diferença das medidas termográficas das imagens por 35 pessoas diferentes, previamente instruídas quanto à técnica de análise, mas que não tinham experiência na prática da termografia. Os resultados obtidos foram 71% de sensibilidade, 85% de especificidade, 0,5267 de repetibilidade e 0,4967 de confiabilidade, o que levaram os autores a concluir que mesmo para observadores inexperientes é possível identificar e distinguir indivíduos doentes de indivíduos saudáveis por meio da termografia. Porém, devido aos baixos valores de confiabilidade e de repetibilidade, é necessária uma padronização das análises e treinamento dos observadores.

Várias são as aplicações da termografia na área médica, das quais pode-se citar o seu uso na neuropatia diabética, na desordem vascular, na detecção do câncer de mama, no estudo da termoregulação do corpo, na triagem de febre, na imagiologia cerebral (termoencefaloscopia), nas aplicações odontológicas, nas aplicações dermatológicas, no diagnóstico de doenças reumatológicas, no diagnóstico da síndrome do olho seco, no monitoramento da pressão sanguínea, no tratamento de doenças hepáticas parasitárias, na detecção de metástase em doença hepática, na isquemia intestinal, no transplante renal, no tratamento cardíaco e na ginecologia (LAHIRI *et al.*, 2012).

Marçal *et al.* (2016) desenvolveram um estudo correlacionando o uso de imagens termográficas com a queixa de dores pelos pacientes em seus corpos, determinando uma doença ocupacional relacionada ao trabalho (DORT), mostrando a importância do uso termográfico na área da ergonomia. O objetivo principal do trabalho foi avaliar o quanto o uso de imagens termográficas pode ser um bom indicador de dor se comparado à avaliação subjetiva de queixa de dor em funcionários encaminhados para reabilitação ortopédica e traumatológica. O estudo avaliou a participação de 18 funcionários voluntários, que responderam a uma avaliação classificando suas dores corporais numa escala de 1 (ausência de dor) a 10 (dor intensa), e posteriormente as imagens termográficas de várias regiões do corpo foram coletadas das quais algumas representavam alterações funcionais nas regiões demarcadas pelos funcionários representando, 84,8% de acerto do exame termográfico. O estudo mapeou as principais regiões corporais lesionadas no trabalho, relatando que a termografia é um bom instrumento de confirmação de pontos de queixa de dor sendo uma abordagem útil para o diagnóstico e acompanhamento de vários distúrbios físicos. É importante ressaltar que alterações funcionais podem ser identificadas sem relatos de queixas de dor, sendo um indicativo de possível lesão futura. Este método tem sido utilizado com sucesso na prevenção de lesões ortopédicas principalmente na área esportiva.

Na odontologia, alguns autores afirmam que a análise termográfica pode ser usada para medir a temperatura da superfície da pele, dos músculos da mastigação e da variação térmica observada na disfunção da articulação temporomandibular (DTM). A DTM é uma condição clínica na qual o emprego da termografia infravermelha vem sendo utilizada como uma ferramenta auxiliar no seu diagnóstico. A disfunção se caracteriza pelo conjunto de alterações clínicas, que envolvem os músculos mastigatórios, a articulação temporomandibular (ATM) e as estruturas associadas. Os seus principais sintomas são dores, limitação da amplitude de movimento da mandíbula, ruídos articulares e falta de coordenação motora (PRESÍDIO *et al.*, 2016). A este respeito, Nahm *et al.* (2007) avaliaram a viabilidade da termografia na avaliação da disfunção da articulação temporomandibular (DTM). Para isso, pacientes voluntários com o diagnóstico clínico de DTM e 31 pacientes voluntários saudáveis foram submetidos a termografia avaliando a diferença de temperatura dos lados opostos das articulações temporomandibulares e dos músculos masseter. O grupo patológico apresentou variações de temperatura na articulação temporomandibular e no músculo masseter entre  $\Delta T = [0,38; 0,40]^{\circ}\text{C}$  e  $\Delta T = [0,33; 0,38]^{\circ}\text{C}$ , respectivamente. Já o grupo de controle apresentou variações entre  $\Delta T = [0,07; 0,10]^{\circ}\text{C}$  e  $\Delta T = [0,10; 0,15]^{\circ}\text{C}$  para os mesmos pontos de avaliação. Mostrando que a termografia pode ser uma ferramenta útil para o diagnóstico da DTM.

A neuropatia diabética é a complicação mais frequente da diabetes, podendo já ocorrer no pré-diabetes. O diagnóstico tardio da neuropatia em diabéticos está associado à maior incidência de complicações, como, por exemplo, ulcerações, amputações típicas do “pé diabético” e risco cardiovascular aumentado, podendo ocorrer morte súbita. Estes fatores provocam alterações da temperatura na superfície da pele, o que torna a termografia uma ferramenta útil para o diagnóstico dessas disfunções (BALBINOT, 2012). Em seu trabalho, Balbinot (2012) realizou um estudo da incidência de neuropatia diabética utilizando a Termografia Computadorizada por Infravermelho, considerando duas variáveis: o Índice de Recuperação Térmica e a presença ou não de Anisotermia

Interdigital. A presença da Anisotermia Interdigital foi considerado um teste mais apropriado para identificar a neuropatia em suas formas iniciais no grupo com diabetes e pré-diabetes, devido à sua simplicidade de aplicação e por suas boas sensibilidade e especificidade, alcançando índice de 81,3% e 46,2% respectivamente. Portanto, a termografia pode ser apresentada como uma boa ferramenta de diagnóstico precoce no rastreamento da neuropatia diabética. Liu *et al.* (2013) integraram a câmera termográfica à rotina clínica de exames realizados nos pés dos pacientes e desenvolveram uma ferramenta quantitativa para análise dos termogramas. Desse modo, a termografia possibilitou a identificação de riscos de úlceras ou outras complicações a partir do aumento ou diminuição da temperatura nos membros avaliados.

O uso das imagens termográficas atraiu a atenção para o diagnóstico da Síndrome Respiratória Aguda Grave (SARS), que é uma doença respiratória grave causada pelo vírus *Coronavirus*. Dentre vários sintomas da manifestação da doença, um deles é uma febre acima dos 38 °C, o que viabiliza o uso da termografia para o seu diagnóstico. Ng, Chong e Kaw (2005) realizaram um estudo avaliando a eficácia do uso de imagens infravermelhas para detecção da SARS. O trabalho avalia as correlações entre as temperaturas da pele facial usando redes neurais artificiais. Diante do risco de um vírus potencialmente letal se espalhar rapidamente, as autoridades chinesas instalaram diversas câmeras termográficas, especialmente nos aeroportos, para verificar a temperatura dos passageiros no saguão de desembarque (RING, JUNG e ZUBER, 2009).

## 2.2 Termografia no diagnóstico ao câncer de mama

O câncer de mama é o câncer mais comumente diagnosticado entre as mulheres, responsável por cerca de 30% dos cânceres. A Tabela 1 apresenta a faixa etária média dos casos de câncer de mama nas mulheres. Segundo estudos, caso seja detectado precocemente, as chances de cura do câncer deste paciente atingem o valor de 85%, se detectados tardiamente essas chances caem para apenas 10%, mostrando toda a importância da detecção precoce da doença (LAHIRI *et al.*, 2012).

Tabela 1 – Incidência do câncer de mama de acordo com a faixa etária média

FAIXA ETÁRIA (anos)	Percentual
até 20	0,0%
20-34	0,9%
35-44	6,0%
45-54	15,0%
55-64	20,8%
65-74	19,7%
75-84	22,6%
acima de 85	15,1%

Fonte: adaptado de LAHIRI *et al.* (2012)

Spitalier e Giraud (1982) realizaram um estudo durante 10 anos, examinando 61000 mulheres, onde a termografia foi o primeiro indicador de câncer de mama em 60% dos casos.

No câncer de mama, células secretam substâncias que causam alterações vasculares na anatomia mamária e formação de novos vasos, os quais causam hipervascularizações e hipertermia nas mamas muito antes do aparecimento de imagem do câncer pelo exame da mamografia. Gamagami, Silverstein e Waisman (1997) realizaram um experimento em 148 pacientes com câncer não-palpável, das quais, pela termografia, 86% foram detectados com uma hipervascularização e hipertermia na mama. E, em 15% dos casos foi realizado uma biópsia na parte suspeita e comprovado a presença de um carcinoma. A evolução de um tumor geralmente está associada à neoangiogênese e ao aumento do fluxo sanguíneo periférico, podendo resultar num aumento da temperatura local da pele de 1 a 2 °C. Desta forma, a imagem termográfica pode representar um método adjunto no monitoramento do crescimento e controle dos tumores (MEIRA *et al.*, 2014).

Em 1956, Lawson observou que a presença de câncer de mama era refletida pelo aumento da temperatura cutânea. Ele, juntamente com Barnes, desenvolveu o termógrafo de Barnes, que é um equipamento que consistia de um bolômetro termistor que detectava a radiação emitida e a transformava em sinais elétricos. Os sinais iluminavam um tubo de gás que brilhavam com uma intensidade proporcional à radiação detectada pelo termistor. A luz era então refletida em um filme fotográfico e produzia, então, um termograma. O tempo médio para este procedimento durava em média, de 10 a 15 minutos, o que dificultava o seu uso para aplicação médica (BRIOSCHI, 2008).

Keyserlinkg *et al.* (1998) relataram que a média do tamanho do tumor a ser detectado pelo exame termográfico é a partir de 1,28 cm enquanto que nos exames mamográficos o tamanho do tumor médio detectável é a partir de 1,66 cm. Segundo Qi e Diakides (2003), as imagens por infravermelho são capazes de detectar o câncer de mama em até 8 a 10 anos mais cedo do que a mamografia.

Head, Wang e Elliott (1993) observaram uma correlação entre a taxa de crescimento de tumores e o seu calor metabólico. Pacientes que apresentam grande crescimento de tumores têm, em geral, seus termogramas mamários bastante alterados. Segundo Ng (2009), um termograma que apresenta variações de temperaturas entre as mamas está associado ao aumento do risco do câncer de mama. Os tumores geralmente apresentam um aumento da taxa sanguínea e metabólica, elevando a temperatura sobre tais áreas, sendo visualizado no exame termográfico. Pacientes com câncer de mama com termogramas cujas temperaturas das mamas apresentam valores assimétricos entre si têm tumores de crescimento mais rápido e são mais propensos a ter metástase. De acordo com Gautherie e Gros (1980), o exame da termografia detecta que 38% das pacientes com termogramas, que apresentam valores temperaturas assimétricos entre as mamas, desenvolverão o câncer de mama nos próximos quatro anos, ou 23% destes pacientes desenvolverão o câncer de mama nos próximos 10 anos.

As assimetrias entre as temperaturas das mamas podem ser difíceis de serem detectadas, portanto, há a necessidade de se desenvolverem técnicas automáticas com bases estatísticas para avaliação dos termogramas, minimizando os erros de uma análise subjetiva. Um operador de desenvolvimento se dá com uma segmentação, onde diferentes características podem ser extraídas a partir dos segmentos, e posteriormente ser utilizado uma ferramenta computacional de classificação, para que a imagem possa ser alocada para determinada classe de acordo com as suas características. Os primeiros parâmetros estatísticos que possuem significados físicos são: média, variância, assimetria e curtose (QI & DIAKIDES, 2003).

Em 2005, Ng *et al.* utilizaram métodos bioestatísticos e redes neurais artificiais para analisar os termogramas da mama. O método utilizava regressão linear, redes neurais artificiais e *Receiver Operating Characteristic analysis* (ROC), onde a regressão linear relaciona as variáveis e o atual estado de saúde do paciente. As principais variáveis eram a média, a moda e a mediana das temperaturas das mamas. Posteriormente era criada uma rede neural artificial baseada nas variáveis com maior correlação com a saída do problema e por fim o ROC era utilizado para avaliar a precisão e a sensibilidade do método, que chegou a 81,2% de sensibilidade e 88,2% de especificidade.

Em 2009, Schaefer, Zavisec e Nakashima desenvolveram uma análise de câncer de mama usando uma série de extrações de características estatísticas de duplo termogramas baseados na classificação da regra *fuzzy*. As características resultaram de uma comparação entre as áreas da mama direita e da mama esquerda e tal comparação quantificou a diferença encontrada em ambos os lados. Os resultados experimentais em um conjunto de cerca 150 casos, mostraram que o sistema de classificação apresentou uma acurácia de aproximadamente 80% nos casos. Com uma performance comparada com a performance de uma mamografia.

Arora *et al.* (2008) utilizaram o modo de rede neural artificial, em imagens digitais por infravermelho, para detecção de patologia mamária, em um grupo de pacientes com suspeita de anomalias detectadas pela mamografia ou pela ultrassonografia. Os autores alcançaram em tal procedimento uma acurácia de 81,80%, com uma sensibilidade de 96,7% e uma especificidade de 26,5%.

Em 2012, Resmini *et al.* desenvolveram um trabalho para verificar a viabilidade do uso de técnicas de reconhecimentos de padrões na classificação de imagens termográficas de pacientes saudáveis ou de portadoras de alguma patologia na mama. Utilizaram características com estatísticas simples, características baseadas na geometria fractal e características de fundamentação geoestatísticas, testando três classificadores diferentes: SVM, KNN e Naïves Bayes, com duas técnicas de redução de características: PCA e Ganho de Informação. O classificador SVM obteve um melhor desempenho, atingindo uma acurácia de 88,23% e uma área abaixo da curva ROC de 0,858, utilizando a seleção de atributos por ganho de informação de 5%. O que se observou neste trabalho foi que o aumento na base de dados, tornando a amostra mais balanceada, contribuiu para o aumento da acurácia.

Em 2012, Acharya *et al.* desenvolveram um classificador de duas classes (Câncer e Não-Câncer) para imagens termográficas usando a técnica de classificação supervisionada (SVM – *Support Vector Machine*) a partir de características de textura. Utilizando 50 imagens termográficas, obtiveram-se uma sensibilidade de 85,71% e uma especificidade de 90,48%. Posteriormente, Acharya *et al.* (2014) utilizaram características na análise de variáveis de alta ordem, provenientes dos termogramas para uma classificação com duas classes (Câncer ou Não-Câncer). Foram extraídas cinco características e avaliadas a partir de um classificador de rede neural artificial (RNA) e de um classificador SVM. O classificador SVM obteve 76% de sensibilidade e 84% de especificidade, enquanto que o classificador RNA obteve 91% de sensibilidade e 88% de especificidade.

Em 2014, Krawczyk e Schaefer promoveram um estudo avaliando termogramas da mama baseados em extração de características e utilizando um sistema de classificação híbrido. A extração de características foi baseada na assimetria entre as mamas do lado direito e do lado esquerdo da paciente. O sistema de classificação hibridiza três técnicas de inteligência computacional: as redes neurais ou suporte de vetor de máquinas (SVM) como a base dos classificadores; um fusor neural para combinar os classificadores individuais; e uma medida *fuzzy* para avaliar a diversidade do conjunto e a remoção de classificadores individuais do conjunto. No presente experimento foram utilizados 146 termogramas dos quais 29 tinham o diagnóstico de tumor maligno, enquanto os demais 117 apresentaram tumores benignos. Os melhores resultados foram obtidos com a utilização do classificador base SVM com uma medida de diversidade *fuzzy*, atingindo uma sensibilidade de 81,96%, uma especificidade de 90,80% e uma acurácia de 89,03%.

Em estudos mais recentes, Araújo (2014) abordou a classificação de anormalidades mamárias desenvolvendo um classificador com três classes: Cisto, Maligno e Benigno. O classificador é baseado em dados intervalares de temperaturas. A etapa de alocação das imagens termográficas nas classes é baseada na distância de Mahalanobis parametrizada. Esta distância é definida através da matriz de covariância comum entre *Inf* e *Sup*, parametrizada para cada classe. Desse modo, um parâmetro de controle  $\lambda_k \in [0,1]$  é definido para cada classe que corresponde ao peso dado a cada limite do intervalo *Inf* e *Sup* na definição da matriz de covariância parametrizada de cada classe. A base de dados do método foi de 50 pacientes. O estudo foi realizado baseado na escolha adequada dos parâmetros  $\lambda_k$  correspondentes a cada classe  $C_k$  que correspondesse a maior taxa de acerto global do classificador combinado com a maior taxa de sensibilidade à Classe Maligno. O melhor resultado foi de 84% de taxa de acerto do classificador e uma sensibilidade para a Classe Maligno de 93%, com resultados bastante satisfatórios superando os valores apresentados por alguns outros algoritmos da área.

Vasconcelos (2017) desenvolveu um estudo aplicando a técnica de vetores sintéticos em diversos classificadores com a utilização de 233 termogramas. Os seus resultados foram bastante satisfatórios alcançando 94,73 % de sensibilidade e 92,10 % de especificidade para a Classe Câncer, em uma classificação binária (Câncer e Não-Câncer), com uma taxa de acerto do classificador de 93,42 %. Quando aplicado em uma

análise multiclasse (Maligno, Benigno, Cisto e Normal) os resultados foram de 80,77 % de sensibilidade e 86,54 % de especificidade para a classe Maligno, com uma taxa de acerto do classificador de 63,46%.

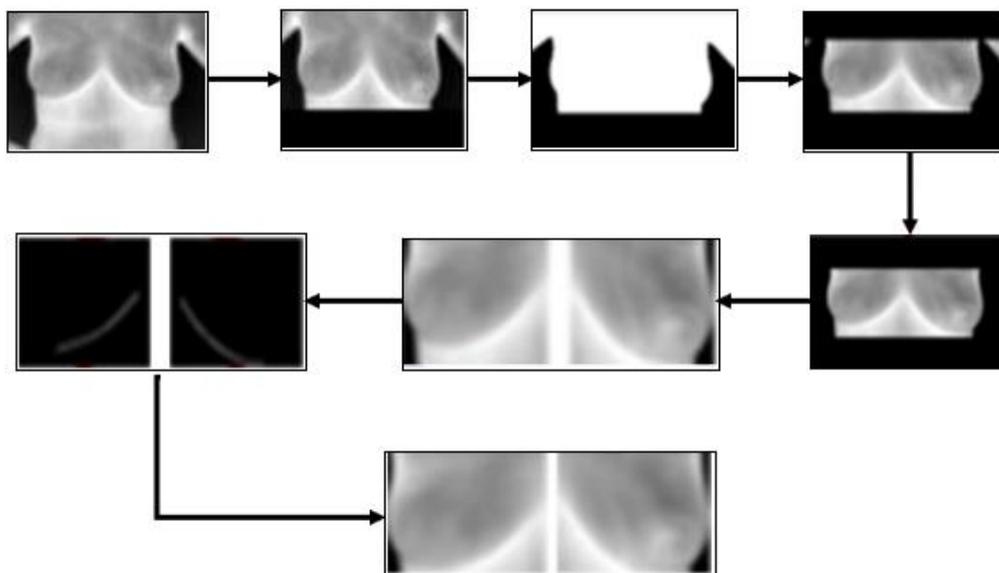
### 2.3 Segmentação

A extração das regiões de interesse em imagens termográficas é um procedimento não muito simples já que, em geral, as imagens não possuem limites visíveis bem nítidos. A segmentação é definida como a separação das regiões de interesse do plano de fundo. Diversas técnicas, tanto automáticas quanto semiautomáticas, foram propostas para que uma segmentação possa ser realizada de maneira mais precisa.

Kapoor e Prasad (2010) aplicaram como procedimento de segmentação das mamas na imagem termográfica a detecção de bordas de *Canny* seguida pela transformada de Hough para identificar as curvas que melhor representem as pregas inframamárias.

Em 2010, Motta desenvolveu um método automático para segmentação de imagens termográficas. As imagens foram convertidas em níveis de cinza. A segmentação desenvolvida pelo autor segue sete etapas ilustradas na Figura 2. O primeiro passo consiste na obtenção da coordenada inferior da segmentação. Posteriormente, há remoção do fundo da imagem. Em seguida é obtida a coordenada superior da segmentação. A quarta etapa consiste na remoção das regiões externas a ROI (*Region of Interest*). Em seguida, as mamas são separadas. Na etapa seis ocorre a detecção da prega inframamária. Finalizando, na sétima etapa, é realizado um deslocamento vertical e é obtida a região de interesse (ROI).

Figura 2 – Procedimento de segmentação proposto por Motta (2010)

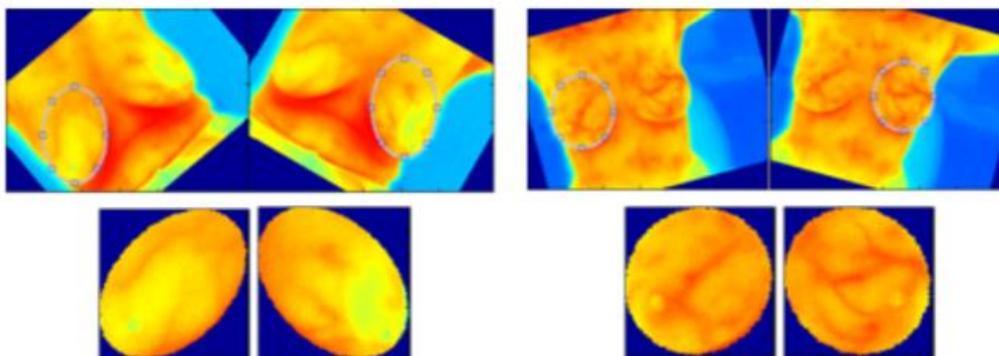


Fonte: MOTTA (2010)

Marques *et al.* (2012) desenvolveram um procedimento de segmentação manual auxiliado por um *tablet*, de modo que o procedimento tem como vantagens a sensibilidade que a tecnologia *touch screen* proporciona e o armazenamento instantâneo das imagens. O procedimento é de certa forma flexível e portátil.

Araújo (2014) desenvolveu um método de segmentação manual numa rotina em Matlab. Os valores correspondentes às temperaturas de cada *pixel* da imagem termográfica são importados pelo *software* e são criadas pseudo-cores correspondentes a esses valores. A imagem é rotacionada com o auxílio de um mouse e é criada uma elipse para cada mama, delimitando a região desejada.

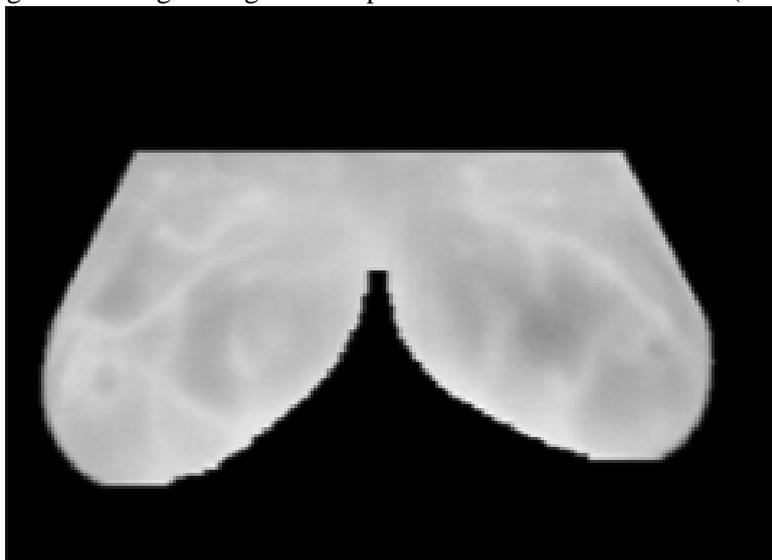
Figura 3 – Segmentação desenvolvida por Araújo (2014)



Fonte: ARAÚJO (2014)

Dourado Neto (2014) criou uma metodologia de segmentação automática para mamas em imagens por infravermelho. A imagem usada apresenta tons de cinzas, onde os tons mais claros indicam as temperaturas mais altas. O procedimento é totalmente autônomo e rápido, não necessitando da influência humana.

Figura 4 – Imagem Segmentada pelo método de Dourado Neto (2014)



Fonte: DOURADO NETO (2014)

## 2.4 Sistema de Múltiplo Classificadores (*Multiple System Classifiers - MSC*)

A ideia geral da combinação de classificadores, parte do conceito intuitivo de que, na maioria das vezes, a conjugação da opinião de diversos especialistas em uma determinada área do conhecimento tende a produzir uma decisão de melhor qualidade do que aquela gerada apenas por um único especialista. A maioria dos esforços despendidos nas pesquisas de combinação de classificadores visa a melhoria da precisão na classificação de padrões, atuando sobre fraquezas e as forças de cada um desses modelos (PONTI JUNIOR, 2011).

Os MSC vêm sendo estudados desde a segunda metade do Século XX, tendo como um dos seus pioneiros Oliver Selfridge, que, em 1959, construiu o primeiro modelo de sistemas com múltiplos especialistas, a arquitetura *Pandemonium* (SELFRIDGE, 1958). Daí por diante, importantes estudos foram publicados sobre o tema, usando diferentes denominações, tais como: comitê, fusão de classificador, combinação, agregação e mistura de especialistas. Atualmente os termos mais comuns são combinação de classificadores, *ensembles learning* e *MSC*, muito usados pela comunidade de aprendizagem de máquina (PONTI JUNIOR, 2011).

De fato, várias pesquisas demonstraram que problemas de classificação são resolvidos com mais precisão quando são usados classificadores combinados, ao invés de um único classificador. Combinar classificadores aparece como um passo natural diante da massa crítica de conhecimento que usam um único classificador (KUNCHEVA, 2004).

Para utilizar plenamente a informação de todo um grupo de classificadores, a saída de cada classificador pode ser combinada com as demais saídas, permitindo uma decisão final que, em grande parte dos casos, melhora as capacidades de generalização e a estabilidade da classificação (PONTI JUNIOR, 2004).

Um *ensemble* é um conjunto de classificadores cujas decisões individuais são combinadas de alguma forma para classificar um novo caso. Tal conjunto foi desenvolvido propondo melhorias na precisão de algoritmos de aprendizado de máquinas (BERNARDINE, 2002).

É natural supor que, combinar classificadores com elevadas taxas de precisão possibilitará a criação de um *ensemble* de melhor desempenho, contudo, outro fator interessante a ser considerado nos MSC é o da diversidade entre os classificadores que o compõe (WOZNIAK *et al.*, 2014). Intuitivamente, pode-se admitir que a combinação de classificadores que cometem erros nos mesmos objetos pouco acrescentará em termos de desempenho do *ensemble* (KUNCHEVA (2004); SANTANA *et al.*, (2007)). Muitos estudos já demonstraram que quanto menor a correlação entre os classificadores em relação aos erros cometidos mais preciso o *ensemble* tende a ser (TUMER & GHOSH, 1996).

A combinação de classificadores é especialmente útil se os classificadores individuais são teoricamente independentes em suas representações (JAIN *et al.*, 2000), ou seja, se possuem atributos diferentes, como num caso do reconhecimento de uma pessoa, tais como: voz, face e impressão digital. Apesar de muitas aplicações possuírem esta característica, esta condição de independência pode ser garantida pelo uso de atributos diferentes, uso de conjuntos de treinamentos diferentes, pela diferença entre os classificadores individuais ou pode ser criado artificialmente através de técnicas como *bagging*, *boosting* e *stacking*. Uma das mais usadas é o *stacking* que insere pesos nos vetores de atributos dependendo da localização do objeto, de forma a “empilhar” os diferentes métodos de treinamento e melhorar a performance da classificação quando combinados (PONTI JUNIOR, 2004).

### 3 FUNDAMENTAÇÃO TEÓRICA

Inicialmente, serão abordados conteúdos referentes à termografia, evidenciando seu princípio físico de funcionamento, baseado na radiação infravermelha. Será compreendido como é o princípio de captação das imagens termográficas por meio das câmeras infravermelhas que serão inseridas no processo de classificação.

Posteriormente, será realizada uma breve abordagem quanto ao processamento da imagem termográfica, da segmentação, das extrações de características e da classificação de imagens termográficas. Serão vistos, também, o conceito de sensibilidade e especificidade de alguma classe, bem como, o entendimento do que é uma matriz de confusão.

Em seguida, serão abordados o conceito e os princípios de otimização, compreendendo seu funcionamento de busca da solução ótima por meio de fundamentos matemáticos com o auxílio de uma ferramenta computacional. Será conceituado a solução de pareto-ótima que serviu de fundamento para o desenvolvimento do procedimento de otimização deste projeto.

O presente capítulo também abordará a ferramenta de otimização de Algoritmos Genéticos, compreendendo seu funcionamento bem como os seus parâmetros que deverão ser inseridos para que o algoritmo tenha o melhor funcionamento.

Posteriormente, será compreendido o funcionamento da combinação de classificadores, fundamentando os benefícios que esta técnica pode trazer para um procedimento de classificação de imagens termográficas.

Finalizando o capítulo, serão apresentadas algumas plataformas computacionais que foram utilizadas durante o projeto. Mostrando os benefícios que estes *softwares* trouxeram para um melhor desenvolvimento do projeto.

#### 3.1 Termografia

A termografia, também chamada de inspeção termográfica, consiste na detecção de ondas eletromagnéticas no espectro infravermelho, não-visíveis pelo olho humano, por meio de uma câmera termográfica. A termografia é um método simples, rápido, de baixo custo, sem contato com o paciente, que não requer contraste e é seguro para crianças e mulheres grávidas. Além disso, é indolor, não-invasivo, e não usa radiação ionizante, utilizada em outros exames médicos. Além dessas características, a termografia tem como vantagem permitir medir a temperatura de corpos em movimento, o equipamento é portátil e a aquisição de dados é simples e rápida. Portanto, se o procedimento não obteve bons resultados, pode ser facilmente repetido. Ela é uma técnica não destrutiva que utiliza

a radiação infravermelha emitida pelos corpos para capturar imagens, os chamados termogramas, e medir temperaturas ou observar padrões diferenciais de distribuição de temperatura com o objetivo de propiciar informações relativas à condição operacional de um componente, equipamento ou processo (ARAÚJO, 2014).

A temperatura é um parâmetro físico associado às noções de frio e calor, bem como à transferência de energia térmica. Do ponto de vista microscópico, ela pode ser definida como a medida da energia cinética associada ao movimento aleatório das partículas que compõem um dado sistema físico. Quanto mais alta a temperatura, mais energia os átomos ou moléculas possuem (SANCHES, 2009).

Quando dois sistemas estão à mesma temperatura, diz-se que eles estão em equilíbrio térmico e não há transferência de calor entre eles. Porém, quando estes sistemas apresentam uma diferença de temperatura, pela 2ª Lei da Termodinâmica, o calor é transferido do sistema de maior temperatura para o sistema de menor temperatura até ambos atingirem um novo equilíbrio térmico. Esta transferência de calor pode ser por condução, por convecção ou por radiação ou por combinações entre esses processos (HALLIDAY, RESNICK e WALKER, 2008).

A transferência de calor por radiação térmica é realizada por meio de ondas eletromagnéticas e ela difere dos mecanismos de transferência de calor por condução e convecção, uma vez que na radiação não é necessário um meio material de propagação para que a transferência de calor ocorra, podendo ser transmitido no vácuo. O mecanismo de emissão está associado à energia liberada como um resultado de oscilações ou transições dos elétrons que constituem a matéria. Essas oscilações são devidas à energia interna e temperatura da matéria. Portanto, a emissão de radiação térmica está associada às condições de excitação térmica no interior da matéria. Todas as formas de matéria emitem radiação (INCROPERA *et al.*, 2008).

A radiação pode ser vista como a propagação de ondas eletromagnéticas. Para tal, propriedades de ondas como padrões de frequência  $\nu$  e de comprimento de onda  $\lambda$  caracterizam o tipo de onda eletromagnética (INCROPERA *et al.*, 2008). As duas propriedades estão relacionadas por:

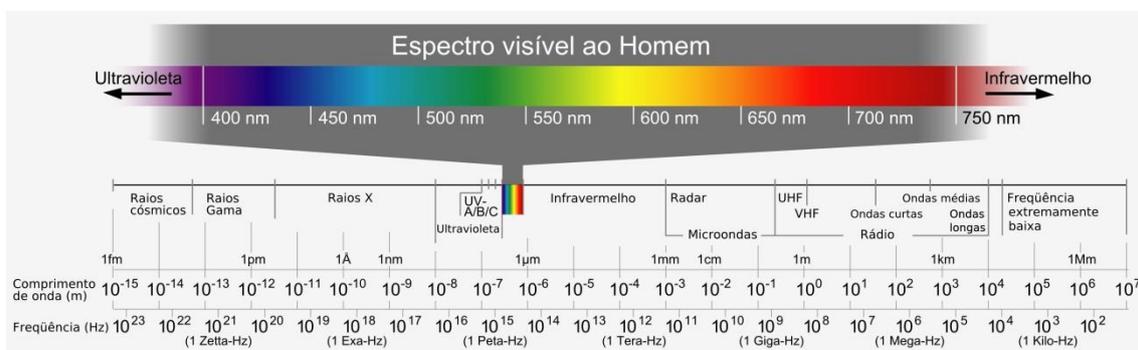
$$\lambda = \frac{c}{\nu} \quad (3.1)$$

onde  $c$  é a velocidade da luz no meio.

O espectro eletromagnético completo, representado por todos os tipos de ondas eletromagnéticas está apresentado na Figura 5, a seguir. Tal espectro inclui os raios gama, Raios-X, radiação ultravioleta, a luz visível, infravermelho, micro-ondas e as ondas de

rádio e TV, numa escala de comprimentos de ondas que varia de  $10^{-10} \mu\text{m}$  para raios cósmicos até valores maiores de  $10^{10} \mu\text{m}$  para ondas de energia elétrica.

Figura 5 – Espectro de ondas eletromagnéticas



Fonte: SBFÍSICA

Numa conceituação mais antiga, a porção do espectro que se estende aproximadamente de 0,1 até  $100 \mu\text{m}$  e que inclui uma fração da ultravioleta, toda a faixa visível e o infravermelho, é chamada de radiação térmica porque afeta o estado térmico ou a temperatura da matéria, sendo a radiação térmica pertinente à transferência de calor. De forma mais atual, considera-se que todo corpo com temperatura acima do zero absoluto ( $0 \text{ K}$  ou  $-273,15 \text{ }^\circ\text{C}$ ) emite radiação, devido à agitação térmica de seus átomos e moléculas (CORTIZO *et al.*, 2008).

A tecnologia aplicada à termografia teve seu início em 1800 d.C. com a descoberta da radiação infravermelha por Frederick William Herschel (RING *et al.*, 2007). Herschel queria descobrir quais as cores responsáveis pelo aquecimento dos objetos. Para isso, ele replicou um experimento realizado por Newton sobre o prisma, porém analisando os efeitos térmicos da luz. Para isso ele colocou um termômetro de mercúrio no espectro obtido por um prisma de cristal com a finalidade de medir o calor emitido em cada cor. Assim, Herschel observou um aumento da temperatura com o deslocamento do termômetro sobre as cores do espectro (do azul até o vermelho), mas ao deslocar o termômetro para além das cores, ele observou que a temperatura continuava a aumentar até um valor limite máximo que se encontrava num ponto a uma considerável distância da cor vermelha. A estes raios acima da cor vermelha, Herschel os chamou de raios caloríficos, região esta, hoje, denominada infravermelho (FLIR SYSTEMS, 2004). O filho de Herschel, John Herschel, repetiu alguns experimentos e obteve com sucesso uma imagem usando radiação solar (RING *et al.*, 2007). Esta foi a primeira experiência que demonstrou que o calor pode ser captado em forma de imagem, como acontece com a luz visível.

Em 1843, Henry Becquerel descobriu que certas substâncias emitiam luminescência quando expostas à radiação infravermelha, e que também poderiam ser

produzidas emulsões fotográficas sensíveis à radiação próxima do infravermelho. O primeiro termograma foi elaborado por Czerny, em 1929. Na metade dos anos de 1940, no período da Segunda Guerra Mundial, foi empregado o Sistema de Visão Noturna em tanques alemães para invasão da Rússia (VERATTI, 1992).

O processo de transferência de calor ocorre sempre que existir uma diferença de temperatura entre corpos ou entre um corpo e o ambiente pelos mecanismos de radiação, condução e convecção. O método termográfico está apenas relacionado à parcela radioativa, sendo que os sensores termográficos trabalham na faixa da região infravermelha do espectro eletromagnético (JARRETA NETO, 2009).

Segundo a lei de Stefan-Boltzmann, a intensidade de radiação térmica emitida ou poder emissivo de um corpo é dependente da sua temperatura e da capacidade de o mesmo emitir radiação, que está relacionada com sua emissividade. A emissividade de um corpo é calculada pela relação entre a energia emitida por um corpo e a energia emitida por um corpo negro na mesma temperatura (ALTOÉ & OLIVEIRA FILHO, 2012). A lei de Stefan-Boltzmann corresponde a Equação 3.2:

$$E = \varepsilon \cdot B \cdot T^4 \quad (3.2)$$

onde:

$E$  – Poder emissivo do corpo a uma temperatura  $T$   $\left(\frac{W}{m^2}\right)$ ;

$\varepsilon$  – emissividade do corpo;

$B$  – constante de Stefan – Boltzmann  $\left(5,7 \cdot 10^{-8} \frac{W}{m^2 K^4}\right)$ ;

$T$  – temperatura absoluta do corpo (K)

Os dois parâmetros mais importantes para um sensor térmico são sensibilidade e resolução. A sensibilidade é medida em graus Celsius. Os sensores de sensibilidade moderada podem detectar diferenças de temperatura na ordem de 0,1 °C e os de boa sensibilidade até quatro vezes menores, ou de 0,025 °C. A resolução da temperatura é análoga ao número de cores no dispositivo de vídeo do computador. A resolução espacial do sensor é determinada pelo tamanho da imagem ou pela quantidade de *pixels* (DIAKIDES *et al.*, 2006).

Quanto mais quente o corpo se encontra, mais radiação infravermelha ele emite. A maior parte da radiação térmica é emitida no comprimento de onda na faixa do infravermelho, invisível ao olho humano. Raios infravermelhos são encontrados no

espectro eletromagnético, localizado no intervalo entre as ondas de rádio e a luz visível, com um comprimento de onda de 0,75 a 1000  $\mu\text{m}$ . A pele humana emite radiação infravermelha, principalmente com comprimento de onda entre 2 a 20  $\mu\text{m}$ , com um pico médio no comprimento de onda entre 9 e 10  $\mu\text{m}$  (AMALU, 2002).

Todos os objetos com uma temperatura superior ao zero absoluto (0 K ou  $-273,15^\circ\text{C}$ ) emitem radiação infravermelha devido ao movimento de seus átomos e moléculas. A intensidade da radiação emitida depende da temperatura do objeto e da capacidade do objeto de emitir radiação. A capacidade de o objeto emitir energia é conhecida como emissividade ( $\epsilon$ ). A energia emitida é proporcional à temperatura de um objeto. O valor da emissividade está compreendido entre 0 (refletida por um espelho) e 1 (corpo negro teórico). A emissividade da pele é muito próxima de um corpo negro ideal, e é igual a 0,98 (SANCHES, 2009).

As imagens termográficas são geradas pelas câmeras termográficas que captam a radiação infravermelha emitida pelos corpos analisados. Esses dados são processados eletronicamente e convertidos numa imagem que representa a distribuição da temperatura superficial do corpo analisado.

Figura 6 – Processo de geração de imagem termográfica



Fonte: SANCHES (2009)

Uma câmera infravermelha é o dispositivo que é usado para converter radiação infravermelha emitida pela superfície do corpo em impulsos elétricos. Um amplificador recebe os sinais elétricos do sensor, amplifica-os para poucos volts, podendo então, serem convertidos em valores digitais. Esses valores são visualizados como uma imagem colorida ou em escala de cinza.

A limitação da aplicação da termografia como técnica de auxílio ao diagnóstico de anomalias está diretamente relacionada às limitações quanto à exatidão das câmeras infravermelhas, ao conhecimento limitado da emissividade do corpo analisado, às características individuais dos tecidos vivos e às condições mal controladas do ambiente.

A radiação que chega até a câmera não é devida exclusivamente do corpo analisado. A radiação proveniente do objeto assim como a refletida pelo mesmo são

atenuadas pela atmosfera antes de atingir a câmera. Desse modo, para realização de uma análise termográfica é importante conhecer fatores que influenciem nos resultados do exame. Dentre eles estão presentes: fatores ambientais (tamanho da sala de coleta, temperatura ambiental, umidade relativa do ar, pressão atmosférica e radiação), fatores técnicos (câmera, protocolo, *software*, análise estatística) e fatores individuais (sexo, idade, antropometria, ritmo circadiano, emissividade da pele, uso de medicamentos e prática de exercício físico). A câmera é responsável por compensar todos esses efeitos da geração das imagens por meios de correlações internas. (CÔRTE & HERNANDEZ, 2016).

### 3.2 Processamento da imagem termográfica

A imagem termográfica pode ser definida como uma função bidimensional  $f(x,y)$  associada a uma matriz de temperatura  $T(x,y)$ , de tal modo que  $x$  e  $y$  representam as coordenadas espaciais e cada elemento  $T(x,y)$  representa a temperatura do ponto  $(x,y)$  (GONZALEZ & WOODS, 2008 apud QUEIROZ, 2016). Cada ponto  $(x,y)$  dessa matriz representa um *pixel*.

As representações das imagens podem ser em pseudo-cor ou em níveis de cinza, de modo que duas componentes estão associadas a esta imagem: uma matriz de temperatura e um mapa de cor. Um termograma é a representação de valores da matriz de temperatura, desse modo cada *pixel* será representado por uma cor correspondente à temperatura situada no mapa de cor.

Embora a representação em cores de um termograma possa variar de acordo com a escala de temperaturas ou com o mapa de cor aplicado que corresponde ao limite de temperatura, sua matriz de temperatura permanece constante, de modo que qualquer análise de processamento de imagem pode ser feita por meio da matriz de temperaturas (ARAÚJO, 2014).

### 3.3 Segmentação

A segmentação consiste na separação da área de interesse do plano de fundo da imagem. Segundo Gonzalez e Wood (2008), a segmentação é o processo de subdividir a imagem em seus objetos e regiões constituintes. O nível a que esta subdivisão é levada depende do problema que se tem o interesse de se resolver, isto é, deve-se parar a segmentação quando os objetos de interesse tiverem sido isolados. Para Dougherty (2009), o procedimento de segmentação pode ser atribuído, também, para o particionamento de uma imagem em regiões significativas. Desta forma, extrai-se a área de maior relevância para um estudo, distinguindo-a de todo o resto.

De acordo com Bankman (2009), o processamento de imagens termográficas, a extração de características ou a mineração de dados dependem de uma correta segmentação da área de estudo.

Uma grande variedade de técnicas de segmentação tem sido aplicada às imagens médicas, no entanto, não existe uma técnica de segmentação padrão que possa produzir resultados satisfatórios para todas as aplicações de imagens. A definição do objetivo de classificação varia com o objetivo de estudo e o tipo de dados da imagem. A segmentação pode ser classificada como: manual, automática ou semiautomática (BANKMAN, 2009).

O procedimento de segmentação pode ser realizado automaticamente, semi-automaticamente ou manualmente. A técnica automática é realizada quando se deseja um procedimento mais rápido com maior objetividade na análise final ou quando se deseja evitar possíveis erros humanos em situações onde a segmentação manual se mostra imprecisa ou de difícil realização. Quando é necessário definir a área de interesse com suporte de um profissional (médico) ou quando é necessário obter a área total da mama, reduzindo possíveis erros de segmentação se realiza a segmentação com a técnica manual (ARAÚJO, 2014; QUEIROZ, 2014).

A segmentação da imagem da mama, tanto de modo automático quanto semiautomático ou manual, pode ser utilizada no suporte ao diagnóstico do câncer mamário. A primeira, porém, pode extrair áreas específicas das mamas de maneira errônea devido à assimetria natural entre elas e às variações anatômicas entre pessoas (ARAÚJO, 2014).

### **3.4 Extração de Características**

O processo de extração de características consiste na extração de informações quantitativas de interesse de um conjunto de dados, que servem como parâmetros de entrada em algum procedimento de classificação (PETTRES & LACERDA, 2012). Uma das importâncias do procedimento de extração de características é a redução de dimensão que ela proporciona no referido conjunto de dados.

As características devem ser robustas, discriminantes, confiáveis e independentes. Nas características discriminantes, os valores dos objetos em classes diferentes devem ser o mais distinto possível. As características são consideradas confiáveis se os objetos de cada classe tiverem valores semelhantes entre si e independentes, se não correlacionadas (DOUGHERTY, 2009).

A seleção de características, dentro do próprio conjunto de atributos extraídos, é uma maneira de identificar quais das características são mais significativas para um procedimento de classificação, eliminando aquelas que não contribuem muito para distinção dos objetos entre as classes (QUEIROZ, 2016).

### 3.5 Classificação de imagens termográficas digitais

Classificar padrões em uma imagem é uma das etapas mais complexas no processamento de imagens digitais. Abordagens diferentes são utilizadas nesse processo visando diminuir o custo computacional e permitir a utilização dos dados extraídos em diferentes domínios de aplicações (PEDRINI & SCHWARTZ, 2008).

A classificação é o procedimento onde se é capaz de decidir em qual grupo ou população um objeto ou pessoa pode ser alocado, levando em considerações características em comum, anteriormente fornecidas (SILVA, 2015).

De acordo com Meneses e Sano (2012), a classificação de imagens é o processo de associar um conjunto de padrões da imagem a um número finito de classes individuais, com base nos seus valores digitais. Se um conjunto de padrões da imagem satisfaz um determinado conjunto de critérios, avaliados por medidas estatísticas, a imagem é atribuída à classe que melhor satisfaz os critérios estabelecidos.

Sistemas classificadores são tipos de máquinas de aprendizado que possuem a capacidade de inferir, baseado nas características de uma dada imagem, a qual classe a referida imagem pertence, a partir de critérios internos da arquitetura de tal classificador (ROCHA, 2016).

Reconhecimento de padrões de imagens é a ciência de encontrar padrões significativos nos dados da imagem que possam ser extraídos por operadores automatizados. O reconhecimento de padrões em imagens é realizado por meio de medições estatísticas, que são derivadas a partir das características espectrais dos *pixels* em uma imagem, a fim de que esta imagem seja destinada à sua mais provável classe, usando uma regra de decisão.

Um padrão pode ser definido como um arranjo de vetores de características (descritores), de modo que um conjunto de padrões que possuem propriedades parecidas formam uma classe de padrões (GONZALEZ & WOODS, 2008).

O procedimento de classificação pode ser do tipo supervisionado ou não-supervisionado (PEDRINI & SCHWARTZ, 2008).

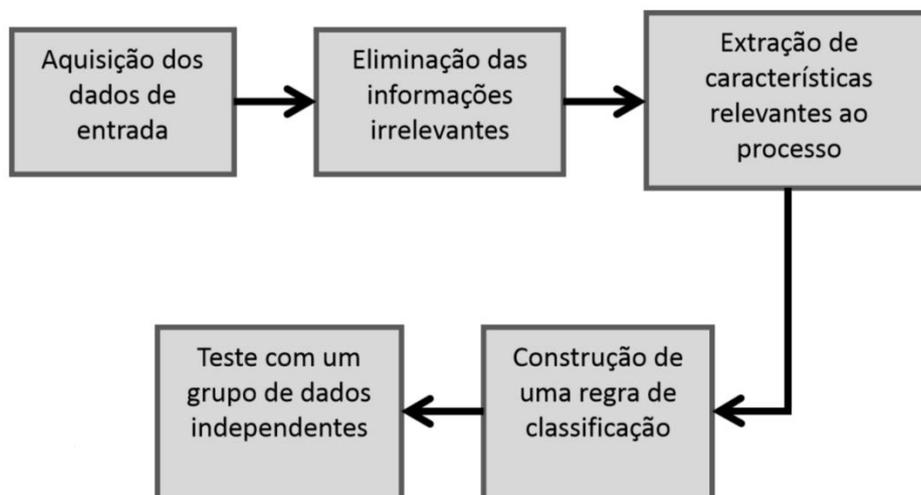
A classificação não-supervisionada requer pouca ou nenhuma participação do analista no processo de classificação da imagem. Inicialmente, são fornecidas classes que não possuem características previamente conhecidas. Assim, todas as informações a respeito das classes serão obtidas a partir das próprias amostras. Isso ocorre quando não se tem suficiente conhecimento acerca do número e da natureza das classes alvo, ou quando se deseja fazer uma classificação exploratória da imagem, para saber as possíveis classes alvo que podem existir na imagem. Contudo, assim como na classificação supervisionada, as amostras que compartilharem propriedades semelhantes devem pertencer à mesma classe.

A classificação supervisionada requer conhecimentos prévios das classes alvo, a fim de classificar a imagem nas classes de interesse pré-fixadas pelo analista. São fornecidas classes previamente definidas onde, para cada uma delas, um padrão comportamental será identificado. Uma etapa de treinamento, responsável pela identificação das características de cada classe, antecede a aplicação dos algoritmos de classificação. O algoritmo necessita ser treinado para poder distinguir as diversas classes. É necessário que as classes apresentem características bem distintas entre si para que não ocorra confusão na classificação.

Os métodos de classificação adquirem informação a partir de um grupo de treino, caracterizando um procedimento de aprendizagem. O aprendizado é uma das principais características no reconhecimento de padrões pelos humanos, o que serviu de inspiração para a criação de máquinas com a capacidade de realizar essa tarefa (SILVA, 2015).

O procedimento de classificação é dividido em etapas, como observado a seguir (Figura 7):

Figura 7 – Processo de classificação de imagens



Fonte: SILVA (2015)

A escolha do classificador é um dos pontos mais importantes para o desenvolvimento de uma aplicação. O tipo de classificador e sua arquitetura podem distinguir características normais e anormais de um padrão. A performance de um classificador depende, também, do conjunto de exemplos usados para o seu treinamento e teste (CARNEIRO, 2015).

Em um classificador é necessário a criação de dois subconjuntos, um de treinamento e outro de teste. Na etapa de aprendizagem de máquina, um determinado padrão é aprendido através de um conjunto de exemplos dados anteriormente, o conjunto

de treinamento. Sendo assim, o classificador aprende a identificar características através de uma amostra de treinamento, gerando uma regra de classificação, que será utilizada nas próximas etapas, para classificar um grupo de dados independentes ou grupo de teste. Na etapa de validação, um grupo de teste é formado para avaliar e validar a regra de classificação criada pelo grupo de treino.

Quando a amostra é pequena, a divisão do conjunto em grupo de treino e grupo de teste pode não fornecer informação suficiente para o treino do classificador. Desse modo, para avaliar a capacidade de generalização de um classificador, podem-se utilizar técnicas específicas como validação cruzada *k-fold*, *leave-one-out* e *bootstrap* (ARAÚJO, 2014).

A técnica de validação cruzada *k-fold* consiste na criação de um conjunto de dados dividido em *k* subconjuntos de tamanhos iguais. Cada subconjunto é usado para teste e os demais para treinamento, repetindo esse processo *k* vezes, de modo que todos os *k* subconjuntos sejam utilizados uma única vez como grupo de teste. Na validação cruzada *leave-one-out* o número de subconjuntos é escolhido como o número de exemplos do grupo de treinamento, ou seja, é necessário construir *n* classificadores, sendo *n* o número de exemplos de treinamento (NILSON, 2014).

### 3.6 Sensibilidade, Especificidade e Matriz de Confusão

A Sensibilidade, a Especificidade e a Matriz de Confusão são parâmetros que servem para qualificar determinado classificador. Ao se realizar um determinado exame médico, os possíveis resultados poderão ser positivo ou negativo (com relação à existência de uma certa patologia). Quando pessoas doentes são corretamente diagnosticadas como doentes, é dito que este exame é Verdadeiro Positivo (VP). Quando pessoas saudáveis são diagnosticadas como pessoas doentes, diz-se que esse exame é Falso Positivo (FP). De forma análoga, quando pessoas saudáveis são corretamente diagnosticadas como saudáveis, classifica-se esse exame como Verdadeiro Negativo (VN) e, quando pessoas doentes são diagnosticadas como saudáveis, classifica-se esse exame como Falso Negativo (FN).

Diante desses conceitos, podem-se definir a Sensibilidade e a Especificidade. A Sensibilidade é a probabilidade de o teste identificar corretamente uma pessoa com doença quando de fato esta pessoa tem doença. Ou seja, a Sensibilidade indica a habilidade do sistema em identificar verdadeiramente uma pessoa doente. A Sensibilidade é calculada da seguinte maneira (MOGHBEL & MASHOHOR, 2011):

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (3.3)$$

A Especificidade é a probabilidade de um teste identificar uma pessoa que não tem doença quando de fato ela não tenha doença. É calculada pela seguinte fórmula (MOGHBEL & MASHOHOR, 2011):

$$Especificidade = \frac{VN}{VN + FP} \quad (3.4)$$

A Acurácia Total de um classificador mostra o desempenho do sistema do diagnóstico e é determinado com base na combinação da Sensibilidade e da Especificidade. É calculada pela seguinte fórmula (MOGHBEL & MASHOHOR, 2011):

$$Acurácia\ Total = \frac{VP + VN}{VP + FP + VN + FN} \quad (3.5)$$

Uma maneira que agrega na avaliação da qualificação do classificador é a análise da Matriz de Confusão. A Matriz de Confusão avalia a quantidade de erros e acertos de acordo com a classe ao qual o objeto foi classificado. A Matriz de Confusão consiste numa matriz que mostra o número de classificações corretas *versus* as classificações preditas para cada classe. O número de acertos de cada classe encontra-se na diagonal principal. Os demais elementos representam erros na classificação. Portanto, um classificador ideal é aquele para o qual todos os elementos da Matriz de Confusão, que não estejam na diagonal principal, sejam nulos. Para melhor compreender, considerando duas classes, A e B, onde a classe A é a classe positiva e a classe B é a classe negativa, a matriz de confusão pode ser representada da seguinte maneira:

Tabela 2 – Matriz de Confusão

		CLASSIFICAÇÃO PREDITA		
		Classe A	Classe B	Nº amostra da classe
VERDADEIRO	Classe A	VP	FN	VP + FN
	Classe B	FP	VN	FP + VN

### 3.7 Coeficiente Kappa

O coeficiente Kappa é um parâmetro de análise que qualifica o desempenho de uma classificação. Ele é definido como uma medida de associação usada para descrever e testar o grau de concordância da classificação.

Apesar de estimar o grau de precisão do método utilizado, o coeficiente Kappa não apresenta informações a respeito da estrutura de concordância e discordância do método, portanto, o coeficiente Kappa deve ser sempre acompanhado de outros parâmetros de qualificação com o objetivo de complementar a análise.

O coeficiente Kappa considera todos os elementos de uma matriz de confusão, assumindo que as unidades são independentes entre si; as classes são independentes e mutuamente excludentes; e o classificador e os pontos de referência operam de forma independente.

A Tabela 3 mostra os valores para os quais o coeficiente Kappa qualifica a classificação.

Tabela 3 – Interpretação do coeficiente Kappa

Coeficiente Kappa	Nível de Concordância
<0	Não existe concordância
0,01-0,20	Concordância mínima
0,21-0,40	Concordância razoável
0,41-0,60	Concordância moderada
0,61-0,80	Concordância substancial
0,81-1,0	Concordância perfeita

Fonte: VASCONCELOS (2017)

### 3.8 Otimização

A otimização busca obter os parâmetros que melhor modelem matematicamente um problema. Otimizar também é buscar a melhor disposição do projeto, sem a necessidade de aplicar todas as alternativas disponíveis, reduzindo-se o tempo de trabalho e o custo do projeto. Segundo Edgar *et al.* (2001), não há um determinado algoritmo de otimização que seja possível aplicar eficientemente para qualquer classe de problemas. A escolha do método depende das características do problema, tais como, funções objetivo, as restrições e variáveis.

O método de otimização tem por finalidade encontrar valores de parâmetros desconhecidos que minimizem uma determinada função-objetivo de forma iterativa. Isto é, estima os parâmetros de modo a tornar mínima a diferença entre o valor medido experimentalmente e o calculado numericamente (BEZERRA, 2013).

Os métodos de otimização podem ser classificados como métodos determinísticos, métodos estocásticos e híbridos (combinação dos outros dois). Os métodos determinísticos baseiam-se na teoria de otimização, buscando o mínimo ou o máximo de uma função-objetivo. A vantagem deste método é o baixo número de avaliações da função-objetivo, obtendo uma convergência rápida e de baixo custo computacional (BRANDÃO, 2010 apud BEZERRA, 2013). A desvantagem destes métodos é que eles podem convergir para um ótimo local e não para um ótimo global. Os métodos estocásticos se baseiam na evolução natural. Sua grande vantagem é que eles convergem para um mínimo ou máximo global. A desvantagem é que esses métodos podem exigir várias avaliações da função-objetivo, tornando-se em alguns casos, métodos inviáveis de aplicação. Recozimento Simulado (*Simulated Annealing*) e Algoritmos Genéticos são exemplos de métodos de otimização estocásticos (BEZERRA, 2013).

Metaheurísticas são métodos de solução que coordenam procedimentos de busca locais com estratégias de alto nível, criando um processo capaz de escapar de mínimos locais e realizar uma busca robusta no espaço de soluções de um problema. Este método vem sendo amplamente utilizado para vários tipos de problemas de otimização, principalmente em aplicações de engenharia, devido à sua capacidade de procura de soluções viáveis, convergindo para uma solução próxima da solução ótima (PHOLDEE & BUREERAT, 2014).

Diferentes metaheurísticas foram desenvolvidas, das quais podem-se citar: Algoritmos Genéticos, Recozimento Simulado e Colônia de Formigas. Esses algoritmos têm se mostrado muito eficazes por funcionar bem para problemas de otimização com múltiplas respostas, já que são capazes de encontrar um conjunto de soluções de uma forma muito rápida (MOGHADDAM *et al.*, 2015).

De acordo com Rao (2009), otimização é o processo responsável por encontrar as condições que proporcionem o valor máximo ou mínimo de uma função. Para Deb (2001), a busca por soluções ótimas para um problema se deve principalmente à necessidade de se minimizar os custos e melhorar qualidade, entre outros fatores.

Os algoritmos de otimização mono-objetivo buscam encontrar uma solução de modo que a mesma seja a melhor possível (ótimo global), ou que se aproxime ao máximo daquela solução. Porém, em problemas de engenharia de modo geral, as formulações de multiobjetivo representam de maneira mais realista e precisa este tipo de abordagem. Para tais casos, os resultados das funções objetivo, por vezes, são conflitantes entre si, consequentemente, a otimização de uma única função não implica na melhoria das outras, sendo necessário analisar em conjunto todas as funções influenciadas pelos parâmetros analisados (REZENDE, 2016).

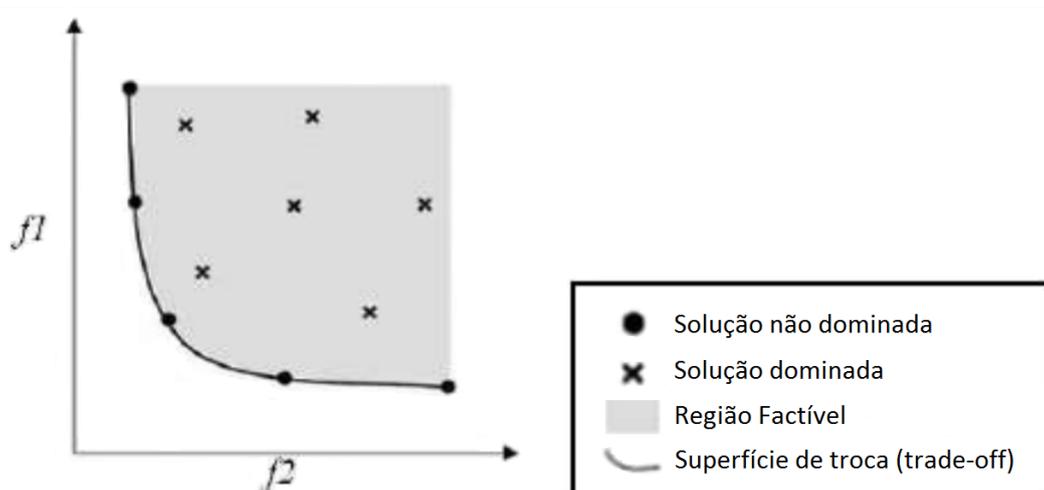
Em um problema de otimização com múltiplas respostas, o objetivo principal é encontrar uma melhor combinação entre as variáveis de entrada do processo, que acarrete como resultado um valor ideal de todas as variáveis respostas. Contudo, em geral, é muito difícil obter essa combinação, porque valores ótimos de uma variável resposta podem não ser os valores ótimos para as demais variáveis respostas (PAL & GAURI, 2010).

No desenvolvimento de determinados processos, é bastante comum que diversas variáveis respostas sejam de interesse. Problemas envolvendo múltiplas respostas têm se tornado cada vez mais relevantes, quando mais de uma característica devem ser avaliadas simultaneamente em um processo (BASHIRI & SALMASNIA, 2009).

O resultado de otimização multiobjetivo gera um conjunto de soluções ótimas chamado de soluções não-dominadas ou soluções pareto-ótimas. Todas as soluções que são pareto-ótimas constituem o conjunto pareto. Os valores objetivos do conjunto de pareto no espaço objetivo constituem a fronteira do pareto. A partir deste conjunto de soluções, um tomador de decisão definirá qual delas é a solução ótima que representa a solução do problema (SUDENG & WATTANAPONGSAKORN, 2015).

Na Figura 8, o espaço acinzentado representa a região no campo dos objetivos, onde se encontram as soluções factíveis existentes. A curva escura ilustra a superfície de troca entre as duas funções objetivo,  $f_1$  e  $f_2$ , e também, uma das fronteiras da região factível. Assim, percebe-se que qualquer alteração na solução implicará na degradação de uma das funções objetivo. Obtendo-se esta fronteira do gráfico de pareto-ótimo, o tomador de decisão irá definir qual a melhor solução, de acordo com as características do problema e a disponibilidade de recursos para sua solução. Problemas com duas funções objetivo facilitam a visualização da fronteira do pareto. Para problemas mais complexos, com mais funções objetivo, é necessário a aplicação de métodos computacionais para a otimização do problema (REZENDE, 2016).

Figura 8 – Gráfico de pareto-ótimo



Fonte: REZENDE (2016)

Para Camargo (2010), um conjunto de soluções provenientes de um problema multiobjetivo consiste em todos os vetores de decisão que não podem melhorar o valor de qualquer objetivo sem que ocorra a degradação de ao menos um dos outros. Estes vetores são conhecidos como *ótimos de Pareto*.

Matematicamente, define-se um problema de otimização multiobjetivo como um problema de se encontrar um vetor de variáveis de decisão  $\omega$  que satisfaça às restrições (OSY CZKA, 1985):

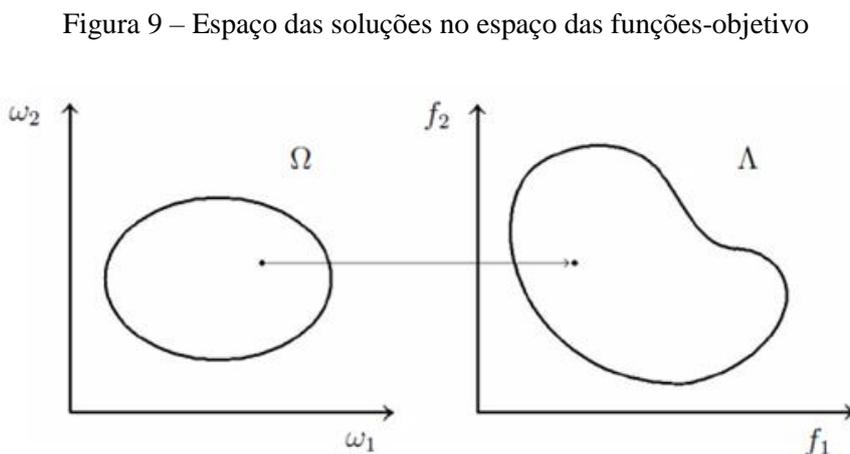
$$\Omega = \{\omega \in R^n \mid M(\omega) \leq 0, N(\omega) = 0, \omega_{min} \leq \omega \leq \omega_{max}\} \quad (3.6)$$

E otimiza-se a função vetorial  $F(\omega)$ , cujos elementos representam as funções objetivo:

$$\text{Minimizar } F(\omega) = [f_1(\omega), f_2(\omega), \dots, f_m(\omega)] \quad m \geq 2 \quad (3.7)$$

sujeito a  $\omega \in \Omega$ .

Também,  $\Lambda = \{\lambda \in R^m \mid \lambda = F(\omega)_{\omega \in \Omega}\}$  é definida como a região factível correspondente para o espaço das funções objetivo. A Figura 9 ilustra um exemplo de mapeamento do espaço das soluções no espaço das funções objetivo no caso bidimensional.



Fonte: RAMPAZZO (2012)

Sendo assim, otimizar significa encontrar valores aceitáveis para as funções objetivo para uma tomada de decisão. Por  $F(\omega)$  ser um vetor, se quaisquer componentes de  $F(\omega)$  competirem entre si, não existirá uma solução única para o problema e sim um conjunto de soluções de compromisso (*trade-offs*). Desta maneira, o conceito de pareto-ótimo deve ser utilizado para a caracterização e obtenção das soluções.

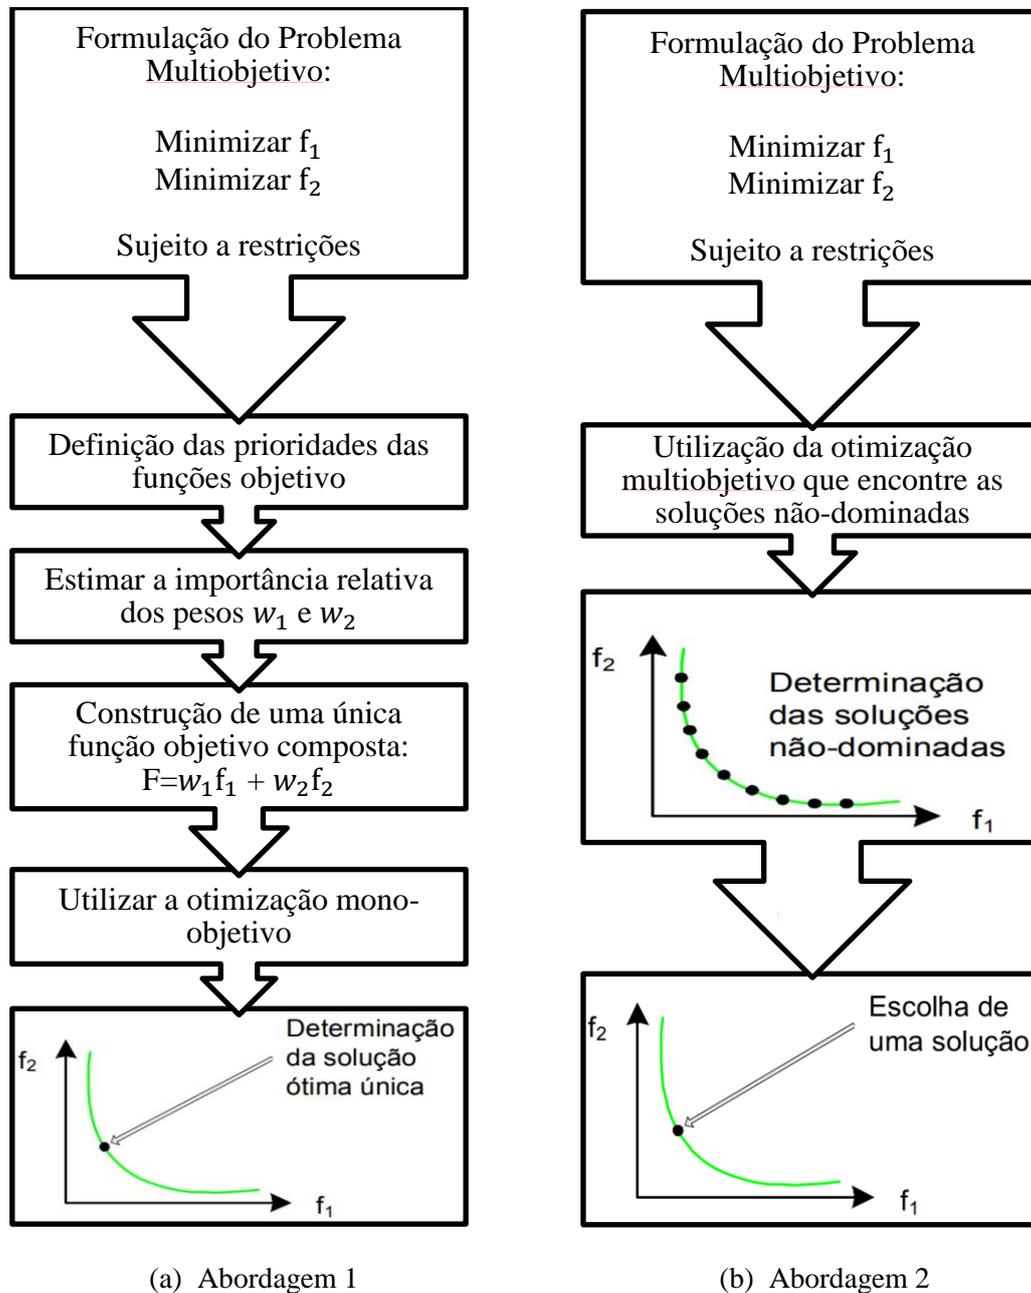
Segundo Paiva (2012), o processo de otimização é dividido em três etapas: a primeira é a modelagem das funções objetivo e das restrições, a segunda é a determinação da estratégia de combinação entre os múltiplos objetivos e, por último, a aplicação de um algoritmo capaz de determinar o ponto de ótimo que atenda ao sistema como um todo. É necessário, também, determinar o método mais adequado para a execução de cada uma destas etapas.

Em otimização multiobjetivo existem duas abordagens para o tratamento do problema (ZINI, 2009):

- 1) Definem-se as prioridades e os pesos entre os vários objetivos de interesse, encontrando a solução ótima baseada nas informações fornecidas;
- 2) Não contendo nenhuma informação adicional, encontra-se o conjunto de soluções não-dominadas para, posteriormente, escolher uma solução nesse conjunto.

Esquemáticamente essas duas abordagens ocorrem da seguinte maneira (ZINI, 2009):

Figura 10 – Esquemas do procedimento de otimização multiobjetivo



Fonte: adaptado de ZINI (2009)

Na Abordagem 1, mostrada na Figura 10a, a grande dificuldade está em estabelecer o grau de importância das funções objetivo por meio dos pesos atribuídos a tais funções. Estabelecidos esses pesos, transformam-se as equações que modelam cada uma dessas respostas em funções utilidade individuais. Em seguida, procede-se a otimização de uma função utilidade global, que é descrita em termos das funções utilidade

individuais. A otimização simultânea de várias respostas transforma-se assim na otimização de uma única função (GOMES, 2015).

Métodos de aglutinação são utilizados para combinar diferentes funções objetivo em uma única função a ser otimizada. O Método de Critério Global é um método de aglutinação, que combina as funções objetivo escalonadas através da atribuição de pesos a cada uma delas, em uma única função que passa a ser o objetivo do problema (RAO & FREIHEIT, 1991).

Por outro lado, existem alguns algoritmos evolucionários que trabalham com problemas apresentado Abordagem 2, Figura 10b. Isso facilita a otimização já que não se é necessário estabelecer pesos às funções objetivo como forma de priorização destas. Estes algoritmos possibilitam a obtenção de um grande número de soluções não-dominadas, das quais é necessário escolher a melhor opção aplicável ao problema.

Em problemas multiobjetivos existe a dificuldade em encontrar informações qualitativas e quantitativas inerentes ao problema. Segundo Zini (2009), é mais interessante e de fácil manuseio utilizar Abordagem 2, apresentada na Figura 10b. Algoritmos evolucionários são preferíveis em relação aos métodos clássicos ou mesmo ao Recozimento Simulado, já que estas duas categorias não foram projetadas para trabalharem com múltiplas soluções, como acontece naturalmente com os Algoritmos Genéticos (CASTRO, 2001).

### 3.9 Erro Percentual Global (EPG)

O critério de decisão para escolha do melhor valor da otimização das respostas pareto-ótimas será indicado pela minimização do Erro Percentual Global (EPG). O EPG mostra o desvio das respostas ótimas da função otimizada em relação aos valores ótimos individuais de cada uma das respostas, avaliando a qualidade da solução encontrada na otimização. Sua formulação é definida por Gomes (2013) da seguinte maneira:

$$EPG = \sum_{i=1}^m \left| \frac{y_i^*}{f_i(X_i^*)} - 1 \right| \quad (3.8)$$

onde,  $y_i^*$  são os valores das respostas pareto-ótimas;

$f_i(X_i^*)$  são os alvos definidos (valores das otimizações individuais).

### 3.10 Algoritmos Genéticos (AG)

Para resolver problemas de otimização multiobjetivos, os métodos baseados em metaheurísticas são as melhores alternativas, pois são flexíveis, eficientes e de fácil implementação. Os objetivos principais de toda metaheurística de otimização multiobjetivo são (ARROYO, 2002):

- Minimizar a distância do conjunto dominante encontrado ao conjunto pareto-ótimo;
- Obter uma boa distribuição das soluções no conjunto dominante gerado.

A grande maioria das aplicações de metaheurísticas para problemas de otimização multiobjetivos são baseados em Algoritmos Genéticos. Esta preferência se dá pelo fato de que os AGs trabalham com uma população de soluções que contém informações sobre várias regiões do espaço de busca e, portanto, oferecem maiores possibilidades de encontrar o conjunto pareto-ótimo ou uma aproximação dele (ARROYO, 2002).

Os Algoritmos Genéticos são técnicas de otimização inspirados no princípio da sobrevivência e reprodução dos indivíduos mais aptos, proposto por Darwin (LUCENA, 2013).

O Algoritmo Genético é um processo de Evolução Natural, que utiliza informações históricas de soluções avaliadas anteriormente na seleção de novos pontos, onde é esperado um melhor desempenho, baseando no critério de seleção e sobrevivência do mais apto (ORTIZ *et al.*, 2004). Este método de otimização difere das demais técnicas de otimização devido ao seu critério de busca global e que este parte de uma população de soluções ao invés de uma única solução (BUSACCA *et al.*, 2001).

Apesar da determinação do conjunto de pontos ser percorrido de forma aleatória, o método de Algoritmo Genético não pode ser considerado um método de busca aleatória não direcionada, já que exploram informações históricas para encontrar novos pontos com melhor desempenho (PAULA, 2015).

Os AGs apresentam muitas vantagens quando comparados a outros métodos de otimização mais convencionais. Os AG são flexíveis e têm a capacidade de produzir soluções de boa qualidade em problemas mais complexos, em tempo computacional viável. Eles exigem pouco da função objetivo e prosperam em ambiente multimodais e até mesmo descontínuos. Com a codificação adequada, eles podem manipular variáveis inteiras ou contínuas ao mesmo tempo além de poder lidar com restrições não lineares e lineares (HERENDIA-LANGNER *et al.*, 2002).

A estrutura de um problema de otimização em Algoritmo Genético pode parecer um pouco complexa, porém facilita a convergência da solução. A terminologia utilizada em Algoritmo Genético é baseada na evolução natural e na genética. Cada solução do método iterativo de otimização é representada por um vetor  $x$  de variáveis independentes,

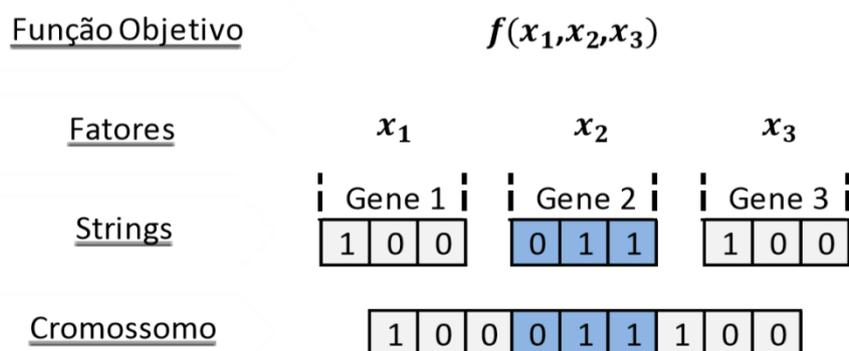
que são codificadas em *cromossomos*. Um *cromossomo* corresponde a uma única solução  $x$  no espaço de solução. Os *cromossomos* são constituídos de *genes*, de tal modo que cada *gene* é responsável por controlar uma ou mais características do *cromossomo*.

Um grupo de soluções (*cromossomos*) existente em cada etapa do algoritmo constitui uma *população*. A substituição da *população* ocorre por meio do procedimento denominado *geração*.

O procedimento para identificação do ponto ótimo ocorre em três estágios: reprodução, cruzamento (*crossover*) e mutação. A princípio se cria uma população aleatória com possíveis soluções para o problema e com a avaliação destes indivíduos em termos da função de objetivo de otimização, denominada função ajuste (*fitness*). Caso a melhor combinação de resultado não seja obtida pela primeira avaliação, pares dos melhores indivíduos são escolhidos como “pais”. Esses pais são combinados, criando uma nova geração de soluções, os filhos. O número da *população* é mantido constante. Posteriormente, ocorre o *crossover* que consiste na troca dos genes dos pais parcialmente, gerando uma descendência criada a partir de uma seleção aleatória. E por fim, ocorre a mutação, onde há a mudança aleatória de 1 para 0 (ou vice-versa) do valor binário do gene. Esta ordem é útil para a seleção dos melhores indivíduos que devem ser escolhidos como pais, servindo como critério de sobrevivência para a próxima geração (GOMES, 2013).

A inicialização é realizada por meio de funções aleatórias para a geração dos indivíduos, com o objetivo de obter uma maior diversidade. O primeiro passo do AG é a codificação das soluções potenciais. A maneira mais utilizada para a codificação consiste na representação de cada solução em forma binária, formando um *cromossomo*, como observado a seguir.

Figura 11 – Criação de um *cromossomo* em Algoritmos Genéticos



Fonte: PAULA (2015)

A *população* é avaliada durante o processo de evolução do algoritmo. Esta avaliação é baseada na função *fitness*, que é a função objetivo do problema. O cálculo da função objetivo é realizado repetidamente ao longo do processo evolutivo. Se a função for complexa, exigirá um custo operacional mais alto. A *seleção* é responsável por determinar quais os indivíduos serão escolhidos para a etapa de reprodução, por meio do critério de sobrevivência do indivíduo mais apto, que apresentam melhores características (GOMES, 2013). É um processo cumulativo, gerando benefícios de geração em geração. Os indivíduos são organizados em um *ranking* de acordo com a sua aptidão e aqueles que apresentam as melhores posições nesse *ranking* são os escolhidos (ARROYO, 2002).

Um bom desempenho do AG ocorre quando a *população* apresenta uma diversidade considerável de modo que não haja excesso de diversidade para não comprometer o desempenho do método de otimização com convergências tardias, ou mesmo a falta de convergência. Portanto, são necessários ajustes adequados dos parâmetros críticos, tais como o tamanho da população, a taxa de *crossover*, taxa de mutação e o número de iterações (BUSACCA *et al.*, 2001).

A sequência de gerações populacionais é interrompida quando o número de gerações atinge o valor pré-estabelecido; ou o tempo de processamento atinge o valor previsto; ou o *fitness* do indivíduo mais fraco atinge um mínimo pré-estabelecido; ou o *fitness* do indivíduo mais forte atinge um valor desejado (GOMES, 2013).

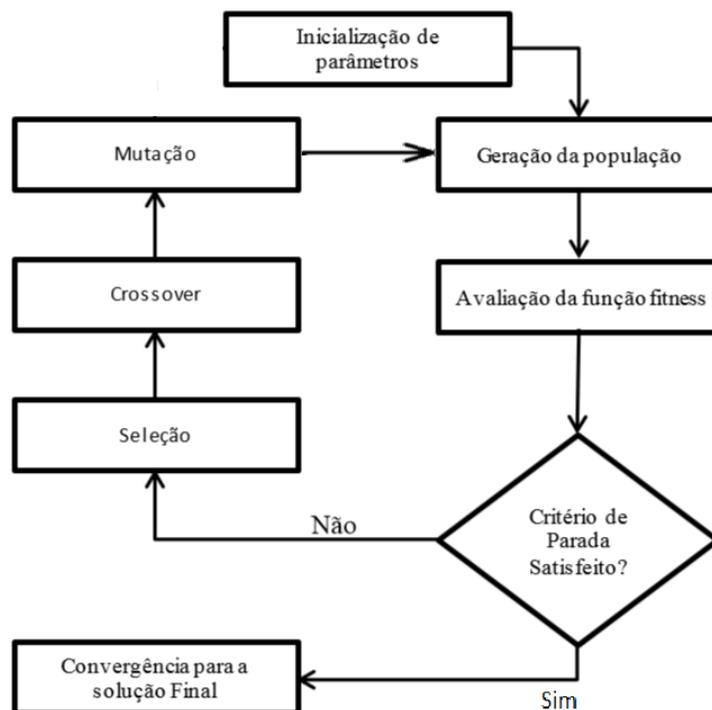
Se o melhor resultado não é obtido na primeira avaliação, o algoritmo segue para a etapa de cruzamento (*crossover*) onde a combinação dos genes dos *cromossomos* pais selecionados criam os filhos que herdarão características positivas dos seus pais. Existem vários tipos de *crossovers*, tais como: *crossover* de um ponto, *crossover* multiponto, *crossover* segmentado, *crossover* uniforme.

Por fim, segue-se para a etapa de mutação, onde são efetuadas pequenas alterações aleatórias nos genes dos cromossomos. A mutação é importante, pois garante a diversidade na população, permitindo uma maior exploração do espaço de busca (PAULA, 2015).

Sendo realizado o cruzamento seguido da mutação, a população é atualizada para próxima geração, no processo chamado de atualização. Em geral, o número de indivíduos da população se mantém constante de geração em geração, já que o número de indivíduos gerados na etapa de cruzamento é igual ao número de indivíduos da população original. Os novos indivíduos substituem os indivíduos da geração anterior. Quando o grau de convergência é atingido, o processo é finalizado.

Esquemáticamente, o procedimento do Algoritmo Genético pode ser bem compreendido pelo seguinte fluxograma (Figura 12):

Figura 12 – Etapas de um Algoritmo Genético



Fonte: adaptado de PAULA (2015)

### 3.11 Combinação de Classificadores

A combinação de classificadores parte do princípio de que uma decisão final realizada por vários classificadores pode gerar resultados melhores do que a decisão de um único classificador. Para isso, classificadores executam a mesma tarefa de categorização e são combinados de forma apropriada.

Um conjunto de classificadores é um conjunto de máquina de aprendizado cujas decisões são combinadas para melhorar o desempenho do sistema padrão de reconhecimento. O uso da combinação de vários classificadores demonstra ser uma ferramenta eficaz para várias aplicações de reconhecimento de padrões. Estudos mostram que problemas de classificação são frequentemente mais precisos quando se usa combinação de classificadores do que uma base de aprendizado individual (PONTE JUNIOR, 2011).

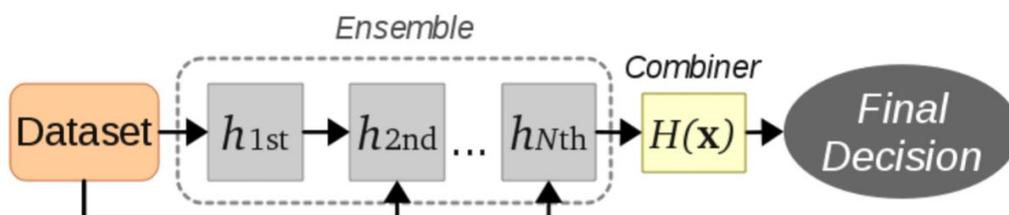
Não existe um único classificador que seja considerado ótimo para todos os tipos de problemas. Assim como não existe um guia claro para a escolha de métodos de aprendizado e é raro quando se tem um completo conhecimento sobre a distribuição de dados bem como sobre os detalhes do comportamento do algoritmo de classificação (WOLPERT, 1996).

De acordo com Dietterich (2000), existem três grandes motivações para se combinar classificadores:

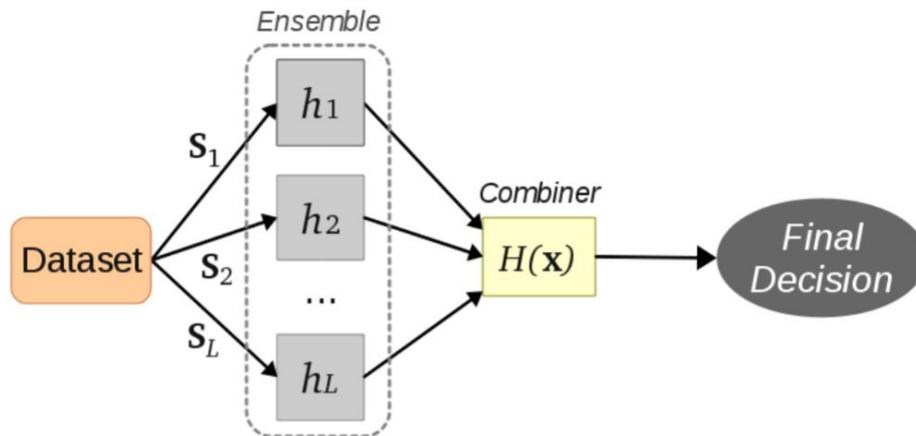
- Motivação estatística: considere um conjunto de padrões  $Z$  e um número de classificadores diferentes com bons desempenhos sobre  $Z$ . Escolhendo-se apenas um desses classificadores para decisão, corre-se o risco de escolher o pior. Combinando estes classificadores, pode-se evitar a escolha apenas do pior classificador e a decisão a ser tomada pela média dos classificadores com desempenho satisfatório. Esta combinação mostra-se ser eficiente em muitas aplicações, porém não garante que tenha um desempenho maior do que o melhor classificador individual.
- Motivação representacional: A combinação de várias hipóteses cria uma nova hipótese, expandindo-se o espaço de hipóteses representáveis. Tal fato pode atingir um desempenho superior ao da melhor hipótese. Isso ocorre, principalmente, quando os classificadores são bem diferentes entre si, cometendo erros de classificação diferentes.
- Motivação computacional: Muitos algoritmos de aprendizagem, ao realizar a busca pelas hipóteses verdadeiras, podem ficar presos em um ótimo local. A combinação de vários classificadores é capaz de evitar isso e de se aproximar da hipótese verdadeira de forma mais eficiente do que com um único classificador, estabilizando o sistema.

É possível combinar os classificadores de duas maneiras: em série ou em paralelo. Na combinação em série, um primeiro classificador é usado e quando este não é mais capaz de classificar um novo padrão, um segundo classificador que é treinado para suprir os erros do classificador anterior é usado. Posteriormente um terceiro é usado no mesmo procedimento, e assim por diante. Na combinação em paralelo, um conjunto de classificadores são treinados de maneira paralela e suas saídas são combinadas, para depois ser tomada a decisão. Este tipo de arquitetura é mais simples.

Figura 13 – Arquiteturas de combinação de classificadores



(a) Em série



(b) Em paralelo

Fonte: PONTI JÚNIOR (2011)

Para que uma combinação de classificadores obtenha um resultado mais satisfatório é necessário que esses classificadores sejam os mais diversificados possíveis, acreditando-se que cada classificador supra a deficiência do outro. No entanto, definir diversidade entre classificadores não é algo trivial, depende tanto da base dos classificadores quanto do método utilizado para obter a decisão final (PONTE JUNIOR, 2011).

Segundo Alpaydin (2004), para se obter resultados produtivos na combinação de classificadores, as decisões de categorização tomadas pelos classificadores não podem ser as mesmas. Decisões iguais levam a resultados iguais. Decisões diferentes permitem a um classificador errar enquanto outros classificadores acertam, resultando em uma decisão final correta.

Dentre as inúmeras funções combinatórias disponíveis, encontram-se a votação, a seleção dinâmica de classificadores e a combinação adaptativa de classificadores. A função combinatória mais simples é a escolha por voto majoritário. A decisão final é obtida escolhendo-se a categoria com maior número de votos entre os classificadores. Ou atribuem-se pesos aos classificadores. Nesse caso o voto do classificador é relativo ao seu peso para a decisão final (LINDEN, 2008).

O desempenho dos sistemas compostos por muitos classificadores é medido principalmente pela taxa de acerto obtida na classificação dos padrões (KUNCHEVA, 2004).

Duas grandes vertentes servem de base para se obter esse melhor desempenho: a escolha dos classificadores e a combinação das decisões (SILVA FILHO, 2014).

O processo de elaboração de uma combinação de classificadores pode ser realizado utilizando o mesmo classificador, gerando multiclassificadores homogêneos ou utilizando diferentes classificadores, com uma multiclassificação heterogênea. Em sistemas de classificação homogêneos, são utilizados diferentes conjuntos de treinamentos para um mesmo algoritmo de classificador. São exemplos desse tipo de combinação o *Bagging* e o *Boosting*. Em sistemas de combinação de classificadores heterogêneos, diferentes algoritmos de classificadores são utilizados para o mesmo conjunto de treinamento. O sistema de combinação de classificadores utilizado neste projeto será o sistema heterogêneo, com a utilização de modelos de combinação dos modelos *Voting* (votação com peso) e *Stacking* (empilhamento).

### Votação com peso

Este sistema de classificação heterogênea faz com que cada classificador apresente um voto à classe que considera ser a mais provável para uma determinada classificação de algum objeto. Posteriormente, é realizada uma contagem da quantidade de votos por classe para cada classificador. A classe que detém a maior quantidade de votos é escolhida como a classificação final para este objeto.

Algumas variações quanto ao modelo de combinação de classificadores com decisão por votos foram propostas. Votação ponderada, votação de máxima confiança e votação com predição de probabilidade são alguns exemplos de variações deste modelo.

O sistema *Voting* é um modelo simples para a construção de um sistema de combinação de classificadores já que este tem a vantagem de requerer pouco recurso computacional e pouco espaço de memória. A desvantagem deste sistema pode ser citada como a possibilidade de ele não conseguir aproveitar ao máximo o melhor desempenho de cada classificador, podendo resultar numa piora de desempenho caso algum classificador base tenha um desempenho global ruim, já que a saída de todos os classificadores tem o mesmo peso independente do seu desempenho individual.

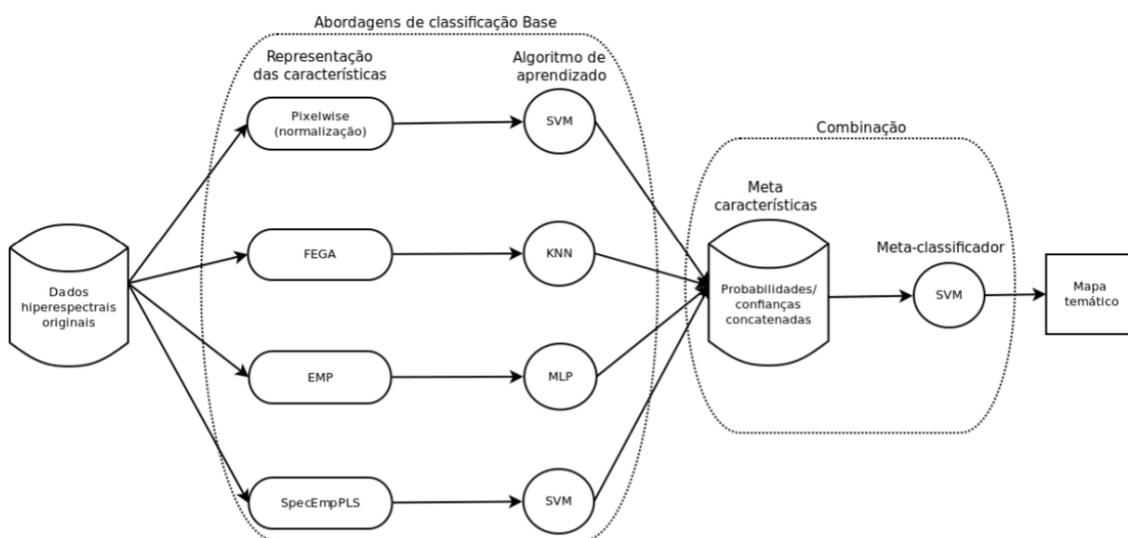
### Stacking

O modelo de combinação de classificadores do tipo *Stacking* é um tipo de combinação heterogênea onde é levado em consideração que determinado classificador apresenta resultados mais seguros do que os outros. O sistema *Stacking* tenta aprender quais dos classificadores são mais confiáveis e descobre a melhor maneira de se combinar suas saídas.

O sistema *Stacking* combina as saídas dos classificadores, induzidos por uma variedade de algoritmos de aprendizado através do mesmo conjunto de dados, através de um outro classificador do qual se espera o melhor desempenho. O modelo *Stacking* é constituído de duas etapas. Na primeira, é gerado um conjunto de classificadores

diferentes e um único conjunto de dados. Na segunda etapa, um único classificador combina as saídas da primeira etapa e realiza uma classificação.

Figura 14 – Modelo de combinação de classificadores *Stacking*



Fonte: SANTOS (2013)

## 3.12 Plataformas computacionais

### 3.12.1 MATLAB

O Matlab é um *software* de alto nível desenvolvido para aplicações em cálculo numérico, análise de dados, cálculo com matrizes, construção de gráficos e implementação de algoritmos. Ele permite a solução de problemas numéricos de maneira mais simples quando comparado a outras linguagens de programação, já que problemas e soluções são escritos de maneira semelhante à maneira como são escritos matematicamente (MATHWORKS, 2016).

O Matlab é um sistema interativo cujo elemento básico de informação é uma matriz. O *software* foi desenvolvido pela MathWorks. Ele é principalmente utilizado em instituições de pesquisa, universidades e empresas (MATHWORKS, 2016).

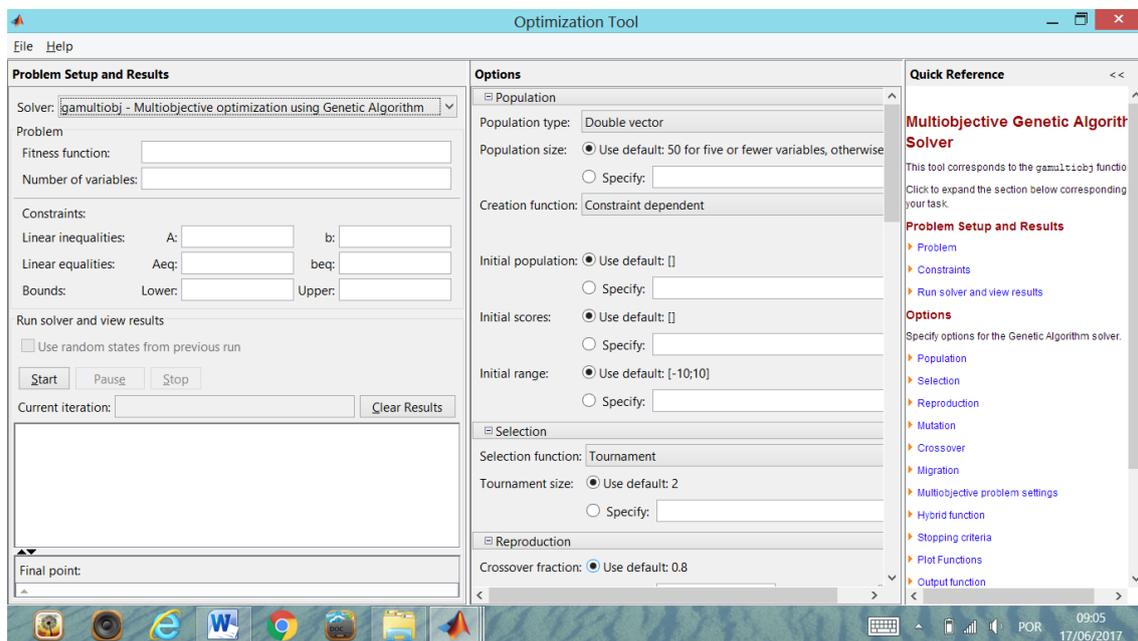
Alguns pacotes para cálculos específicos podem ser incorporados a rotinas pré-definidas do Matlab. Um desses pacotes é a ferramenta *Optimization Toolbox* que fornece funções para encontrar parâmetros que minimizem ou maximizem funções objetivo. A caixa de ferramentas inclui métodos de otimização para programação linear, programação quadrática, otimização não-linear e mínimos quadráticos não-lineares, servindo para solucionar problemas contínuos e discretos.

Um dos métodos de otimização que pode ser utilizado no Matlab é a função `@ga`, que corresponde a aplicação de Algoritmo Genético (*Genetic Algorithm*) que é uma ferramenta para se encontrar o ponto de mínimo de uma função objetivo. Uma variação do Algoritmo Genético no próprio Matlab ocorre por meio da função `@gamultiobj` que corresponde à otimização multiobjetivo usando Algoritmo Genético. Com essa função é possível encontrar a parte de pareto-ótimo da função *fitness* por meio de Algoritmo Genético.

Para que a função `@gamultiobj`, obtenha uma resposta otimizada do problema de maneira correta, é necessário determinar alguns parâmetros de entrada na função, tais como a função *fitness*, correspondente à função objetivo, os limites de fronteira superiores e inferiores dos parâmetros de resposta, além das restrições do problema. Outros parâmetros, como citado anteriormente na fundamentação de Algoritmo Genético, devem ser incluídos para uma melhor resposta do método de otimização. Estes parâmetros são: População, Seleção, Reprodução, Mutação, *Crossover* e Migração.

A interface é bastante intuitiva e de fácil aplicação, já que o próprio programa explica como usar cada tipo de ferramenta (Figura 15).

Figura 15 – Interface da função de otimização multiobjetivo no Matlab



Fonte: MATLAB

Além deste pacote de otimização, o Matlab apresenta como umas das principais funções uma ferramenta de linguagem de programação. Foi através desta que Araújo (2014) desenvolveu o procedimento de segmentação manual e o classificador usados neste trabalho.

### 3.12.2 Minitab

Minitab é um programa de computador voltado para aplicações com fins estatísticos. É um *software* muito utilizado principalmente nas universidades e em empresas voltadas para gerenciamento. Sua interface é em forma de planilhas, numa maneira bastante simples de se utilizar.

O Minitab apresenta várias funções de procedimento estatístico. Dentre elas, pode-se citar: Controle de Qualidade, Planejamento de Experimentos, Análise de Confiabilidade e Estatística Geral. Uma das funções utilizadas no *software* pelo presente trabalho foi um procedimento de regressão juntamente com o Método de Mínimos Quadrados para se modelar funções baseadas em dados das variáveis.

### 3.12.3 WEKA

O WEKA (*Waikato Environment for Knowledge Analysis*) é um *software* desenvolvido pela Universidade de Waikato, na Nova Zelândia, dedicado ao estudo de técnicas de aprendizagem de máquinas. O *software* foi desenvolvido com o intuito de permitir aos pesquisadores uma ferramenta de fácil e livre acesso às técnicas de aprendizagem de máquina.

O WEKA contém uma biblioteca com diversificados métodos de classificação, permitindo ao usuário experimentar e comparar diferentes métodos de aprendizado de máquina.

Além de o *software* conter ferramentas de algoritmos de aprendizagem, ele permite que pesquisadores implementem novos algoritmos de acordo com as suas necessidades. O WEKA contém um conjunto considerável de algoritmos de aprendizado de máquinas e ferramenta de processamento de dados. O *software* disponibiliza em sua interface algoritmos de regressão, classificação, agrupamento e seleção de atributos.

O WEKA realiza a análise computacional e estatística dos dados fornecidos por meio de técnicas de mineração de dados tentando, a partir dos padrões encontrados, gerar hipóteses para soluções.

A interface do *software* se constitui de painéis com determinadas funções: pré-processamento de dados; classificação, onde algoritmos para modelos de classificação e regressão de aprendizagem são utilizados para avaliação dos resultados do processo de aprendizagem; *cluster*, que são algoritmos de agrupamentos; e seleção de atributos, que constitui métodos de identificação de subconjuntos de atributos dos dados.

## 4 METODOLOGIA

O presente trabalho apresenta três abordagens metodológicas que foram usadas para aperfeiçoar a técnica de utilização de classificadores para o diagnóstico de anomalias mamárias. A primeira e principal abordagem desta dissertação visa à otimização da ferramenta de classificação desenvolvida por Araújo (2014), por meio da melhor escolha dos parâmetros que serão mostrados adiante.

A segunda abordagem metodológica do projeto consiste em utilizar outra ferramenta de classificação de imagens termográficas, cujo procedimento segmentação utilizado é o automático desenvolvido por Dourado Neto (2014). Os resultados obtidos nesta metodologia serão comparados àqueles alcançados utilizando a metodologia 1.

Por fim, será realizada uma avaliação na combinação de classificadores baseado na metodologia realizada por Vasconcelos (2017). A autora obteve resultados de classificação utilizando diferentes classificadores do *software* WEKA. O estudo apresentado nesta dissertação parte da ideia de que, combinando-se os classificadores, seria possível obter resultados mais satisfatórios do que se estes fossem utilizados individualmente. Desse modo será observado se há uma influência positiva na taxa de acerto e na sensibilidade da classificação quando tais classificadores são combinados.

### 4.1 Metodologia 1

A presente abordagem consiste em utilizar o classificador desenvolvido por Araújo (2014) e realizar algumas modificações com o objetivo de qualificar esse classificador, transformando-o em uma ferramenta de classificação de imagens termográficas mais completa com um campo de aplicação mais amplo, com a inclusão de uma nova classe (Classe Normal), além de tornar o processo de classificação mais rápido e eficaz. O classificador desenvolvido por Araújo (2014), em sua forma original, realiza a classificação de imagens termográficas de acordo com as anomalias mamárias, classificando-as em três classes: Maligno, Benigno e Cisto. O critério de classificação é baseado na distância de Mahalanobis parametrizada. Um dos objetivos deste trabalho é a inclusão da Classe Normal.

Além da ampliação do número de classes para este classificador, de três para quatro classes, a presente metodologia também apresentará uma análise quanto ao aumento da base de dados, observando se com este procedimento, há alguma influência nos resultados obtidos.

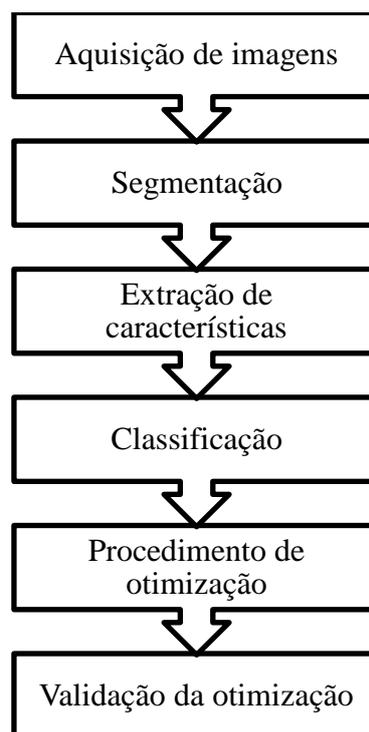
A primeira modificação do projeto apresentado nesta dissertação se deu na ampliação da quantidade de classe deste classificador. Araújo (2014) desenvolveu um algoritmo de classificação de anomalias mamárias contendo três classes (Maligno,

Benigno e Cisto). Nesta dissertação foi proposta uma ampliação do número de classes de três para quatro classes (Maligno, Benigno, Cisto e Normal). A Classe Normal representa aquelas mamas que não apresentam nenhum tipo de anomalia, as consideradas mamas saudáveis. Desse modo, o classificador se tornou mais completo já que o exame termográfico foi ampliado, alcançando qualquer paciente com qualquer tipo de mama, sendo saudável ou não. A ampliação de classes foi realizada modificando o algoritmo desenvolvido no Matlab.

Realizadas as modificações, o classificador foi utilizado em uma base de classificação contendo as quatro classes para que, assim, se averiguesse a influência e o comportamento dessas modificações nos resultados de classificação, analisando a eficiência do classificador quando este trabalha com quatro classes, bem como observando a influência da Classe Normal sobre seus resultados.

A Figura 16 apresenta de maneira sucinta as etapas que foram realizadas nesse projeto para alcançar os melhores resultados de classificação:

Figura 16 – Fluxograma das etapas de classificação e otimização



#### 4.1.1 Aquisição das imagens termográficas

As imagens termográficas utilizadas neste trabalho foram obtidas por meio de uma câmera infravermelho do modelo FLIR S45. Estas imagens foram adquiridas de pacientes

voluntárias do Ambulatório de Mastologia do Hospital das Clínicas (HC) da Universidade Federal de Pernambuco (UFPE), em um período entre 2005 e 2014. As pacientes analisadas no presente trabalho já tinham um diagnóstico concluído, realizado por exames clínicos convencionais, mamografia ou ultrassonografia, bem como a biópsia confirmando seu diagnóstico, quando necessário esse exame. O projeto teve a aprovação do Comitê de Ética da UFPE e foi registrado no Ministério da Saúde sob CEP/CCS/UFPE Nº 279/05, de novembro de 2005, e as pacientes assinaram o Termo de Consentimento Livre e Esclarecido (TCLE), permitindo e confirmando total consciência na finalidade do projeto.

Com a finalidade de reduzir possíveis erros gerados pelas variações térmicas do ambiente onde o exame é realizado ou variações de temperatura das pacientes, foi utilizado um protocolo revisto e ampliado por Oliveira (2012) para realização do exame termográfico de mamas. Este protocolo estabelece alguns padrões que devem ser seguidos para que resultados mais precisos possam ser alcançados. Ele trata tanto dos cuidados referentes às pacientes, quanto aos cuidados referentes ao procedimento de aquisição da imagem. Esta padronização foi definida com o objetivo de se obter imagens térmicas em condição de aquisição uniforme para fins de comparação. Um aparato mecânico foi projetado e construído para o posicionamento dos braços das pacientes. Além da construção de um carro com trilhos onde é posicionada a câmera termográfica e seu tripé.

Figura 17 – Aparato Mecânico



Fonte: OLIVEIRA (2012)

Para que haja um equilíbrio térmico entre a paciente e o ambiente de exame, é necessário um tempo de aclimatação. Foi estabelecido como padrão, uma espera de cerca de dez minutos para minimizar os efeitos da atividade metabólica da paciente e para que ocorra este equilíbrio de temperatura entre a paciente e o ambiente.

Alguns parâmetros devem ser inseridos na câmera termográfica, para que os efeitos do ambiente sobre os resultados das imagens sejam quantificados pela mesma. Para isso, são inseridos, na câmera, os valores da umidade relativa da sala, da distância da câmera à paciente e da emissividade da pele humana, que segundo Sanches (2009) é de 0,98.

#### 4.1.2 Base de dados

O presente trabalho utilizou uma amostra de 87 imagens termográficas, das quais, 22 pacientes foram diagnosticadas com tumor benigno, 27 com tumor maligno, 22 com cisto e 16 pacientes sem nenhuma anomalia mamária.

Duas formas de análise foram realizadas, uma apenas com as anomalias (Maligno, Benigno e Cisto) utilizando o classificador no seu modelo original, desenvolvido por Araújo (2014). Esse procedimento de análise foi realizado para observar a influência do aumento da base de dados nos resultados, já que Araújo (2014) utilizou apenas 50 imagens, das quais 19 eram com pacientes com tumor benigno, 14 com tumor maligno e 17 com cisto. A segunda análise foi feita com a inclusão da Classe Normal, modificando o classificador desenvolvido por Araújo (2014) e foi observada a influência da Classe Normal nos resultados da classificação. A base de dados de imagens termográficas utilizada foi a seguinte:

Tabela 4 – Base de dados para a classificação

<b>Diagnóstico</b>	<b>Quantidade</b>
Normal	16
Tumor Benigno	22
Tumor Maligno	27
Cisto	22
<b>Total</b>	<b>87</b>

#### 4.1.3 Segmentação

O procedimento de segmentação das regiões de interesse (ROI) foi realizado de maneira manual através de uma rotina desenvolvida, no Matlab, por Araújo (2014). O

método é baseado na matriz de temperaturas correspondente à imagem termográfica e consiste na separação das regiões de interesse do plano de fundo.

A matriz de temperaturas foi obtida por meio do *software FLIR QuickReport*, que extrai uma matriz de dimensão 320x240, onde cada elemento dessa matriz contém o valor da temperatura de um *pixel*. Esta matriz foi convertida em uma planilha de texto e importada pelo Matlab.

O Matlab processou esses dados convertendo esses valores de cada elemento da matriz em pseudo-cores por meio da função *imagesc( )*, de modo que esta atribui aos valores numéricos da matriz, cores que vão do azul ao vermelho, gerando uma imagem pseudo-colorida em conjunto com uma legenda numa régua de cores, que mostra os valores correspondentes a cada cor.

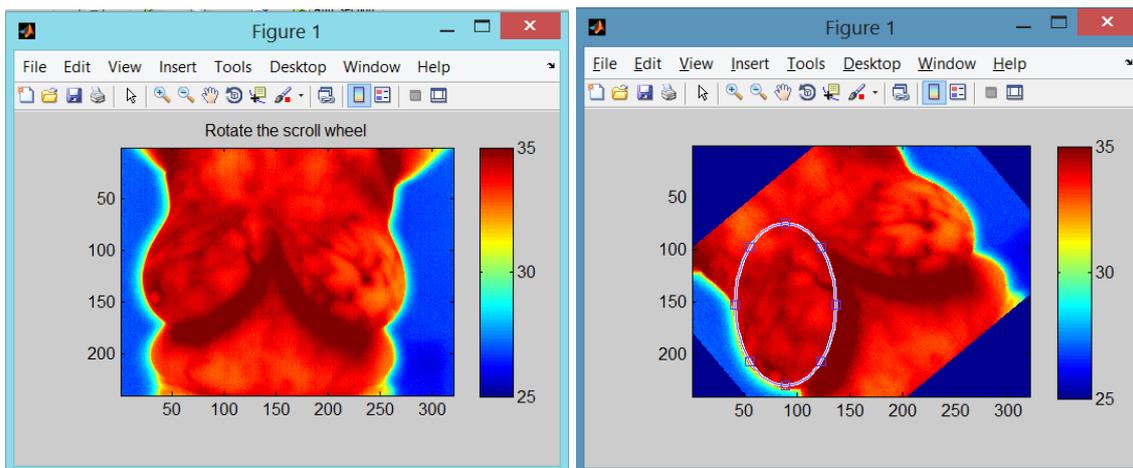
O processo manual de segmentação ocorreu com o auxílio de um mouse, onde o usuário delimita a região de interesse de cada mama, gerando uma área elíptica sobre estas mamas. A figura pode ser rotacionada por meio do botão *scroll* do mouse para que a elipse se ajuste da melhor maneira, abrangendo a melhor área possível sobre a mama.

Esse procedimento gerou uma máscara sobre a área delimitada, de modo que esta foi rotacionada, em seguida, de volta à posição original, permitindo a extração da área de seleção, através da interseção dessa máscara com a imagem original, não rotacionada. Assim foi realizada a segmentação de ambas as mamas. O processo ocorreu da seguinte maneira como mostram as figuras a seguir (Figuras 18, 19, 20 e 21):

Figura 18 – Matriz de temperaturas exportada do *software FLIR QuickReport*

	C238	23.79																						
	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	AA	AB	AC
7	32.14	32.13	32.01	32.05	32.06	32.19	32.06	32.1	32.21	32.25	32.24	32.36	32.17	32.29	32.34	32.3	32.34	32.59	32.64	32.62	32.31	32.35	32.43	32.31
8	31.93	32.15	32.25	31.93	31.88	32.07	32.01	32.17	32.18	32.14	32.37	32.27	32.28	32.31	32.46	32.37	32.41	32.46	32.44	32.48	32.63	32.61	32.45	32.55
9	32.14	32.16	32.13	32.04	31.95	32.05	32.13	31.99	32.37	32.15	32.22	32.21	32.33	32.41	32.32	32.42	32.2	32.42	32.43	32.56	32.4	32.59	32.43	32.51
10	31.87	32.2	32.09	32.05	31.95	32.02	32.23	32.12	32.33	32.3	32.24	32.16	32.4	32.36	32.32	32.33	32.36	32.48	32.49	32.47	32.41	32.41	32.54	32.35
11	32.22	31.98	32.25	32.12	32.09	32.07	32.2	32.05	32.36	32.28	32.17	32.28	32.09	32.29	32.31	32.5	32.39	32.44	32.25	32.51	32.54	32.25	32.4	32.55
12	32.27	32.23	32.16	32.35	32.23	32.13	32.42	32.11	32.25	32.37	32.26	32.32	32.14	32.4	32.44	32.23	32.47	32.42	32.57	32.53	32.47	32.52	32.44	32.31
13	32.46	32.35	32.29	32.14	32.15	32.35	32.32	32.2	32.26	32.48	32.49	32.46	32.33	32.44	32.43	32.47	32.41	32.47	32.49	32.44	32.74	32.58	32.48	32.51
14	32.25	32.33	32.5	32.21	32.28	32.33	32.37	32.2	32.39	32.45	32.32	32.4	32.42	32.34	32.3	32.25	32.44	32.55	32.44	32.65	32.67	32.65	32.68	32.45
15	32.34	32.4	32.32	32.19	32.29	32.23	32.32	32.19	32.32	32.33	32.35	32.53	32.31	32.58	32.53	32.49	32.44	32.37	32.59	32.67	32.65	32.61	32.39	32.31
16	32.64	32.49	32.41	32.34	32.33	32.3	32.24	32.29	32.42	32.58	32.52	32.42	32.36	32.47	32.45	32.49	32.4	32.34	32.56	32.47	32.54	32.46	32.5	32.32
17	32.67	32.54	32.6	32.51	32.34	32.29	32.54	32.32	32.45	32.57	32.49	32.43	32.51	32.46	32.41	32.47	32.4	32.44	32.29	32.65	32.81	32.48	32.54	32.52
18	32.79	32.66	32.74	32.56	32.47	32.47	32.53	32.39	32.43	32.42	32.56	32.54	32.61	32.64	32.43	32.4	32.56	32.48	32.34	32.44	32.45	32.58	32.59	32.25
19	32.56	32.87	32.75	32.67	32.52	32.49	32.27	32.54	32.51	32.58	32.36	32.51	32.47	32.5	32.49	32.58	32.57	32.37	32.47	32.57	32.95	32.46	32.64	32.27
20	32.72	32.79	32.89	32.63	32.54	32.53	32.42	32.39	32.68	32.54	32.55	32.6	32.53	32.38	32.36	32.6	32.33	32.51	32.47	32.47	32.47	32.32	32.28	32.31
21	32.71	32.84	32.93	32.73	32.61	32.74	32.51	32.44	32.52	32.5	32.53	32.73	32.39	32.67	32.64	32.55	32.58	32.44	32.52	32.47	32.4	32.32	32.45	32.32
22	32.65	32.82	32.79	32.83	32.78	32.75	32.62	32.45	32.61	32.64	32.57	32.48	32.4	32.46	32.49	32.59	32.42	32.44	32.53	32.37	32.37	32.28	32.24	32.3
23	32.79	32.68	32.85	32.85	32.74	32.71	32.76	32.67	32.62	32.6	32.67	32.45	32.42	32.42	32.4	32.53	32.59	32.52	32.48	32.48	32.42	32.38	32.29	32.32
24	32.68	32.69	32.8	32.88	32.91	32.9	32.57	32.43	32.66	32.83	32.2	32.4	32.44	32.45	32.51	32.47	32.41	32.39	32.36	32.34	32.38	32.18	32.35	32.32
25	32.54	32.81	32.86	32.74	32.84	32.74	32.83	32.54	32.52	32.56	32.49	32.35	32.46	32.5	32.55	32.47	32.44	32.31	32.24	32.44	32.39	32.23	32.22	32.32
26	32.53	32.74	32.76	32.74	32.73	33.01	33.04	32.68	32.77	32.67	32.64	32.49	32.47	32.5	32.51	32.43	32.34	32.42	32.24	32.43	32.38	32.26	32.42	32.45
27	32.43	32.45	32.56	32.53	32.74	32.75	32.97	32.57	32.67	32.64	32.51	32.61	32.44	32.5	32.53	32.33	32.34	32.27	32.44	32.34	32.32	32.28	32.36	32.17
28	32.41	32.4	32.48	32.65	32.62	32.82	32.78	32.6	32.34	32.54	32.61	32.49	32.45	32.34	32.44	32.45	32.39	32.31	32.34	32.42	32.17	32.31	32.2	32.2
29	32.22	32.3	32.37	32.62	32.45	32.84	32.75	32.84	32.78	32.59	32.49	32.56	32.4	32.43	32.39	32.44	32.34	32.11	32.22	32.48	32.2	32.01	32.27	32.14
30	32.07	32.35	32.36	32.43	32.53	32.67	32.71	32.71	32.66	32.58	32.38	32.57	32.3	32.3	32.56	32.26	32.21	32.27	31.88	32.19	32.12	32.17	32.2	32.2
31	32.01	32.27	32.34	32.28	32.3	32.51	32.77	32.49	32.77	32.62	32.64	32.38	32.44	32.33	32.39	32.25	32.4	32.28	32.25	32.24	32.05	31.88	32.22	31.9
32	32.24	32.33	32.42	32.33	32.23	32.68	32.52	32.67	32.63	32.66	32.59	32.38	32.41	32.34	32.21	32.32	32.36	32.05	32.08	32.09	31.91	32.04	31.97	31.75
33	32.12	32.02	32.15	32.24	32.2	32.56	32.71	32.52	32.62	32.57	32.57	32.3	32.48	32.26	32.22	32.09	32.19	32.18	32.06	31.93	31.93	31.79	31.86	31.66

Figura 19 – Imagem colorida correspondente aos valores da matriz de temperatura



(a) Imagem vista no Matlab

(b) Imagem rotacionada com a região delimitada

Figura 20 – Máscara criada sobre a região delimitada

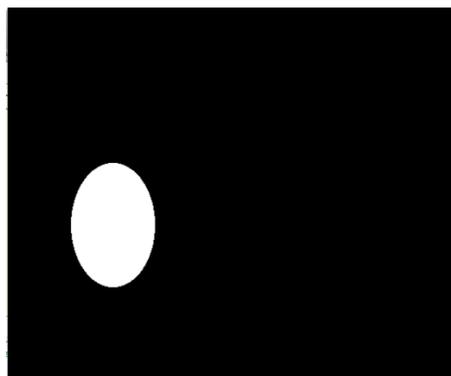
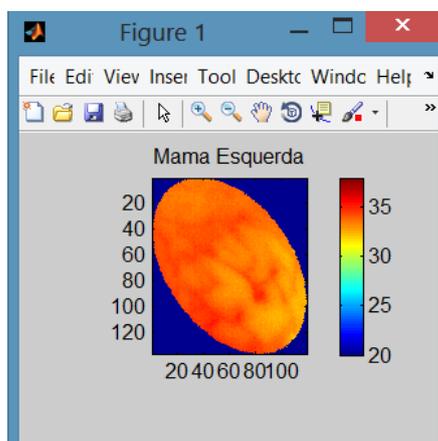
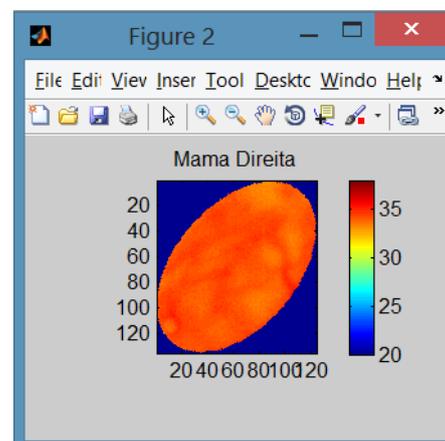


Figura 21 – Imagem das regiões segmentadas das mamas esquerda e direita



(a) Mama esquerda



(b) Mama direita

Após a segmentação, foi realizado um procedimento de morfologia matemática para cada mama. Tal procedimento é uma ferramenta de processamento de imagens que estuda propriedades estruturais da mama por meio das suas imagens e tem o objetivo analisá-las por meio do uso de ferramentas de operadores morfológicos, melhorando o aspecto visual da anomalia mamária. Isso foi feito, obtendo-se um Incremento Localizado de Temperatura (ILT), definido pela diferença entre a máxima temperatura e uma temperatura local média (TANG *et al.*, 2008 apud ARAÚJO, 2014). O ILT foi calculado nas áreas das mamas segmentadas, baseado nas matrizes obtidas na segmentação. O procedimento se deu com a escolha de um elemento estruturante (ES) que é um conjunto definido servindo de domínio da imagem para a transformação a ser realizado sobre o pixel selecionado. O ES deve ter o tamanho suficiente como domínio para comportar todo o tamanho da mama. Após a escolha do ES, foi realizado um procedimento de abertura, que é definido como um processo de erosão seguindo de um processo de dilatação da imagem. A subtração da imagem obtida após a abertura com a imagem original representa as amplitudes de aumento de temperatura localizado em relação ao plano de fundo de temperaturas da imagem original, definindo o ILT. A partir das informações do ILT para cada *pixel* de cada mama, foram obtidas duas matrizes independentes, definidas como Matriz Morfológica da Mama Esquerda ( $M_{ME}$ ) e Matriz Morfológica da Mama Direita ( $M_{MD}$ ).

#### 4.1.4 Extração de Características

Após o procedimento de segmentação, é realizada a extração de características por meio de uma abordagem onde são usados os intervalos de temperaturas referentes às quatro matrizes de entrada: matrizes segmentadas da mama esquerda (ME); da mama direita (MD); e suas respectivas matrizes morfológicas ( $M_{ME}$  e  $M_{MD}$ ). Essas variáveis intervalares são usadas como valores de entrada para um classificador de distância mínima que usa como função de proximidade uma variação da distância de Mahalanobis baseadas em intervalos. O procedimento de extração de características está devidamente explicado em Araújo (2014). Em imagens termográficas, um intervalo de temperatura é obtido a partir das temperaturas contidas na região de interesse e definido como,  $Y = [T_{min}, T_{max}]$ , onde  $T_{min}$  representa a temperatura mínima da região de interesse e  $T_{max}$  representa a temperatura máxima da região de interesse. Sendo assim, as matrizes de entrada geram um vetor de características intervalares de quatro dimensões  $\mathbf{Y}$ , definido por:

$$\mathbf{Y} = (a, b, c, d) \quad (4.1)$$

onde:

$$a = [\min_{MD}, \max_{MD}];$$

$$b = [\min_{ME}, \max_{ME}];$$

$$c = [\min(MD, ME), \max(MD, ME)];$$

$$d = [\min\{\max_{M_{MD}}, \max_{M_{ME}}\}, \max\{\max_{M_{MD}}, \max_{M_{ME}}\}].$$

Figura 22 – Representação gráfica dos intervalos de temperatura das matrizes segmentadas das mamas direita e esquerda e de suas respectivas matrizes morfológicas



(a) Intervalos de temperaturas da segmentação

(b) Intervalos de temperaturas morfológicas

Fonte: ARAÚJO (2014)

Posteriormente, cada intervalo destes é separado em suas componentes de centro e raio, criando dois novos vetores contínuos de quatro dimensões,  $\mathbf{w}_c$  e  $\mathbf{w}_r$ , correspondentes ao vetor de centros dos intervalos e ao vetor dos raios dos intervalos, respectivamente.

Em seguida, estes dois vetores contínuos gerados são transformados para um novo espaço bidimensional de características a partir do critério de Fisher, com o objetivo de criar um novo espaço de características, separando melhor as classes, e facilitando a etapa de classificação. O critério de Fisher consiste em maximizar um critério  $J_F$  que representa a razão entre as matrizes de covariância entre-classes e as matrizes de covariância intra-classe. A saída desta etapa são dois vetores bidimensionais (um para centros e outro para raios)  $\mathbf{x}_m$  e  $\mathbf{x}_r$ , respectivamente. Com estes vetores, é criado um novo vetor intervalar  $\mathbf{v}$  que representa a projeção dos intervalos originais em um espaço de características alternativo, onde:

$$\mathbf{v} = [\mathbf{x}_m - \mathbf{x}_r, \mathbf{x}_m + \mathbf{x}_r] \quad (4.2)$$

#### 4.1.5 Classificação das imagens termográficas

Extraída as características, estas são utilizadas como entradas para a classificação. O classificador utilizado é o classificador de distância mínima para dados intervalares. O procedimento de classificação foi desenvolvido por Araújo (2014).

Para melhor compreender o classificador, considere  $E = s_1, \dots, s_n$  um grupo de  $n$  objetos simbólicos descritos por  $p$  variáveis. Os objetos  $s_i$  ( $i = 1, \dots, n$ ) são representados por um vetor de intervalos  $\mathbf{v}_i = ([\alpha_i^1, \beta_i^1], \dots, [\alpha_i^p, \beta_i^p])^T$ . Sendo  $P$  uma divisão de  $E$  em  $K$  classes ( $C_1, \dots, C_K$ ), de tal modo que cada classe  $C_k$  ( $k = 1, \dots, K$ ) possui um protótipo  $L_k$ , também representado como um vetor de intervalos  $\mathbf{g}_k = ([\alpha_k^1, \beta_k^1], \dots, [\alpha_k^p, \beta_k^p])^T$ , onde  $\mathbf{g}_k$  corresponde ao vetor de médias dos intervalos de  $C_k$ . Para  $j = 1, \dots, p$ :

$$\left[ \alpha_k^j = \frac{\sum_{i \in C_k} a_i^j}{n_k}, \beta_k^j = \frac{\sum_{i \in C_k} b_i^j}{n_k} \right] \quad (4.3)$$

onde  $n_k$  representa a quantidade de elementos na classe  $C_k$ .

O classificador de distância mínima distribui um objeto  $\mathbf{v}_i$  para a classe  $C_k$  se

$$d^\lambda(\mathbf{v}_i, \mathbf{g}_k) \leq d^\lambda(\mathbf{v}_i, \mathbf{g}_r) \quad \forall k, r = 1, \dots, K \quad (4.4)$$

A função  $d^\lambda = (\mathbf{v}_i, \mathbf{g}_k)$  corresponde a uma distância de Mahalanobis parametrizada para intervalos. A distância de Mahalanobis entre duas observações intervalares  $\mathbf{x}_i$  e  $\mathbf{y}_k$  é definida como (SOUZA *et al.*, 2004 apud ARAÚJO, 2014):

$$\delta(\mathbf{x}_i, \mathbf{y}_k) = d(x_{iL}, y_{kL}) + d(x_{iS}, y_{kS}) \quad (4.5)$$

onde:

$$d(x_{iL}, y_{kL}) = (x_{iL} - y_{kL})^T S_I (x_{iL} - y_{kL}) \quad (4.6)$$

representa a distância de Mahalanobis entre os vetores de *Inf* (*Infimum*) que corresponde ao valor mínimo do intervalo analisado, no caso, o valor mínimo de temperatura sobre a

região de interesse,  $x_{iI}$  e  $y_{kI}$ . E  $S_I$  representa a matriz de covariância obtida para os valores de *Inf*, e

$$d(x_{iS}, y_{kS}) = (x_{iS} - y_{kS})^T S_S (x_{iS} - y_{kS}) \quad (4.7)$$

corresponde à distância de Mahalanobis entre os vetores de *Sup* (*Supremum*) que corresponde ao valor máximo do intervalo analisado, no caso, o valor máximo de temperatura sobre a região de interesse,  $x_{iS}$  e  $y_{kS}$ . E  $S_S$  representa a matriz de covariância obtida para os valores de *Sup* (ARAÚJO, 2014).

Desse modo, a distância de Mahalanobis parametrizada pode ser definida através da matriz de covariância comum entre *Inf* e *Sup*, parametrizada para cada classe  $C_k$ . O parâmetro de controle para cada classe  $C_k$  será considerado o  $\lambda_k \in [0,1]$ , ( $k = 1, \dots, K$ ). A distância de Mahalanobis parametrizada entre dois vetores intervalares  $\mathbf{v}_i$  e  $\mathbf{g}_k$  pode ser definida de acordo com a Equação 4.8, a seguir:

$$d^\lambda(\mathbf{v}_i, \mathbf{g}_k) = (\mathbf{v}_{iI} - \mathbf{g}_{kI})^T \mathbf{S}_k(\lambda_k) (\mathbf{v}_{iI} - \mathbf{g}_{kI}) + \quad (4.8)$$

$$(\mathbf{v}_{iS} - \mathbf{g}_{kS})^T \mathbf{S}_k(\lambda_k) (\mathbf{v}_{iS} - \mathbf{g}_{kS})$$

Onde  $\mathbf{S}_k(\lambda_k)$  representa uma matriz de covariância parametrizada para a uma determinada classe  $C_k$  que é definida com base em um parâmetro de controle  $\lambda_k \in [0,1]$ . Este parâmetro mede o grau de influência entre os limites dos intervalos, isto é, correspondem ao peso dado a cada limite do intervalo *Inf* e *Sup* na definição da matriz de covariância parametrizada de cada classe. Quando o valor de  $\lambda_k$  é considerado nulo significa que para a classe correspondente a este parâmetro  $\lambda_k$ , a matriz de covariância comum será representada pela matriz de covariância *Inf*, quando este parâmetro  $\lambda_k$  é unitário, significa que a matriz de covariância comum será representada pela matriz de covariância *Sup*. E quando este valor está compreendido entre 0 e 1, a matriz de covariância comum é resultado de uma combinação entre as matrizes de covariância *Sup* e *Inf*. Desse modo, a matriz de covariância parametrizada da classe  $C_k$  é definida por:

$$S_k(\lambda_k) = \frac{(1-\lambda_k)S_{kI} + \lambda_k S_{kS}}{(1-\lambda_k)n_k + \lambda_k n} \quad (4.9)$$

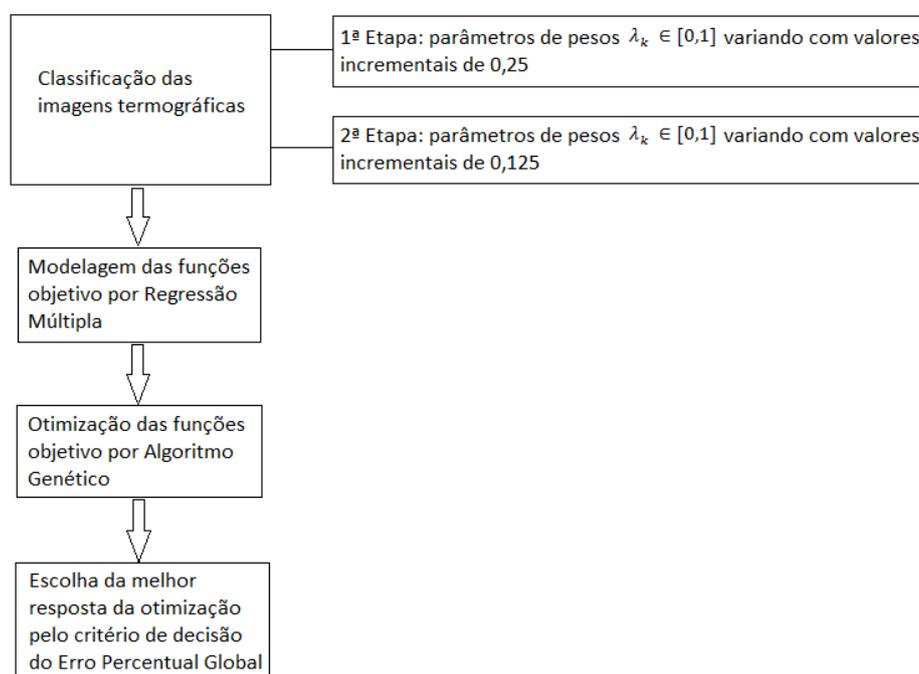
onde  $S_{kl}$  e  $S_{kS}$  representam, respectivamente, as matrizes de covariância para os valores de *Inf* e *Sup* da classe  $C_k$ ;  $n_k$  representa a quantidade de elementos na classe  $C_k$  e  $n$  representa o número global de elementos.

Para encontrar o valor ideal de cada  $\lambda_k$ , um procedimento iterativo foi desenvolvido no Matlab, variando cada  $\lambda_k$  em valores de 0 até 1 com valores incrementais, de maneira sucessiva. O processo será discutido a seguir. Os valores de todos os parâmetros de peso, correspondente a cada classe, são combinados de modo que a melhor combinação escolhida é aquela cujos resultados das taxas de acerto e da taxa de sensibilidade à Classe Maligno do classificador são as maiores possíveis.

#### 4.1.6 Definição dos parâmetros $\lambda_k$ através da otimização

O procedimento de otimização proposto segue alguns passos conforme observado no fluxograma da Figura 23 abaixo.

Figura 23 – Fluxograma do processo de otimização dos parâmetros de peso  $\lambda_k$



O processo iterativo do classificador foi realizado em duas etapas: na primeira, foi utilizado o algoritmo de classificação desenvolvido nesta dissertação, numa rotina do Matlab, baseado no classificador desenvolvido por Araújo (2014). Foram realizadas sucessivas classificações baseadas na combinação dos parâmetros  $\lambda_k$ , de modo que cada

parâmetro  $\lambda_k \in [0,1]$  variasse com valores de incrementos de 0,25. Isto é, cada parâmetro  $\lambda_k$  começou em 0, depois assumiu o valor de 0,25; depois 0,5 e assim sucessivamente até chegar a 1. Desse modo, cada  $\lambda_k$ , correspondente a cada classe  $C_k$ , assumiu cinco valores compreendidos entre 0 e 1. A iteração foi realizada por uma combinação entre todos os valores de todos os parâmetros  $\lambda_k$  de cada classe, compondo um número total de iterações de  $5^k$ . Para quatro classes, o número de iterações foi igual a  $5^4 = 625$ .

A segunda etapa do procedimento iterativo consistiu em realizar o mesmo procedimento da etapa anterior, porém com valores incrementais de 0,125, além, da redefinição dos valores limites dos parâmetros  $\lambda_k$ . Esses novos valores limites do parâmetro  $\lambda_k$  foram definidos baseados num critério de valor de sensibilidade à Classe Maligno, definido pelo usuário.

Para isso, o algoritmo foi programado para guardar apenas as combinações dos  $\lambda_k$  que atingiram um valor mínimo estipulado da sensibilidade à Classe Maligno. Desse modo, criou-se uma base de dados com todas as combinações dos parâmetros  $\lambda_k$  que obtiveram um valor de sensibilidade à Classe Maligno maior ou igual ao critério estipulado. E, desse modo, os valores mínimos e máximos dos parâmetros  $\lambda_k$  definidos para a segunda etapa do procedimento iterativo foram os valores mínimos e máximos dessa base de dados criada com a primeira etapa do processo iterativo. Na pior das hipóteses, esses valores mínimos e máximos para os parâmetros  $\lambda_k$  serão 0 e 1, porém, limites de intervalos mais enxutos poderão surgir, diminuindo o número de passos do procedimento iterativo da segunda etapa.

Assim como na primeira etapa iterativa, a segunda etapa também será condicionada a um critério, definido pelo usuário, de valor mínimo desejado à sensibilidade à Classe Maligno. As combinações dos  $\lambda_k$  cujo valor da sensibilidade à Classe Maligno atenda ao critério serão guardadas formando uma nova base de dados, contendo as combinações dos parâmetros  $\lambda_k$  juntamente com os seus respectivos valores das sensibilidades à Classe Maligno e da taxa de acerto (ou taxa de erro) do classificador relacionado às combinações dos  $\lambda_k$ . Essa base de dados servirá como parâmetro de entrada para a modelagem das funções criadas por meio da regressão múltipla.

Sendo assim, esses valores da base de dados citados serão utilizados num procedimento de regressão múltipla, que consiste em modelar matematicamente uma função, que representa uma relação entre as variáveis de entrada e de saída. As variáveis definidas como de entradas foram os parâmetros  $\lambda_k$ . As variáveis de saídas escolhidas foram a taxa de acerto e a sensibilidade à Classe Maligno, criando-se, portanto, dois procedimentos de regressão, gerando duas funções, um para cada variável de saída.

O procedimento de regressão utilizado foi a regressão múltipla, já que se utiliza mais de uma variável de entrada para cada variável de saída. Foram definidas duas funções de regressão, uma função criada para a taxa de acerto e outra função criada para a sensibilidade à Classe Maligno, já que estes dois parâmetros foram tomados como os que melhores qualificam o classificador. Porém, mais funções poderiam ter sido obtidas

de acordo com a vontade do usuário do classificador, como por exemplo, para sensibilidade às demais classes ou até mesmo para a especificidade a qualquer uma das classes.

Os modelos matemáticos utilizados que representam as respostas são obtidos por regressão múltipla. As funções foram obtidas com o auxílio do *software* Minitab. Através da função *Estat > Regressão > Regressão > Ajuste de Modelo de Regressão*. Após a construção do modelo, é necessário avaliar se o mesmo apresenta significância estatística. Isso é realizado pelo próprio *software* por meio da avaliação do ajuste do modelo, verificando quais os termos são significativos para o mesmo. A avaliação da qualidade do ajuste do modelo ocorre por meio do coeficiente de determinação ajustado ( $R_a^2$ ), que representa o percentual de variação na resposta que é explicada pelo modelo matemático. Isto é, quanto o modelo foi capaz de explicar os dados coletados. Os valores de  $R_a^2$  podem ser atribuídos de 0 a 1. Um  $R_a^2 = 1$  significa um perfeito ajustamento enquanto que um  $R_a^2 = 0$  significa nenhuma correlação entre o modelo criado e os dados. Resultados de  $R_a^2$  maiores do que 60% são considerados bons, significando relações fortes entre as variáveis correlacionadas. Outro parâmetro a ser analisado é obtido por meio do resultado do teste de falta de ajuste, onde o parâmetro *p-value* é analisado para observar se os coeficientes correspondentes a esse *p-value* são significativos ou não. Para serem significativos os *p-values* devem ser menores do que 5%.

As funções criadas por meio da regressão são as funções objetivo que serão inseridas no procedimento de otimização. A otimização é realizada com o auxílio do Matlab, na função de Algoritmo Genético para múltiplas funções objetivo. Os parâmetros de entrada em tal procedimento são: as funções objetivo que serão otimizadas, limites superiores e inferiores dos parâmetros, população, seleção, reprodução, mutação, cruzamento e o critério de parada. As funções objetivo foram as funções de regressão da taxa de acerto e da sensibilidade à Classe Maligno. Os limites superiores e inferiores dos parâmetros foram definidos em 0 e 1, respectivamente, que são os limites inferiores e superiores dos parâmetros de peso  $\lambda_k$ . Os demais parâmetros do Algoritmo Genético foram mantidos na forma padrão, como aparece no *software*. A população foi definida com o tipo de vetor duplo. A seleção foi por torneio, onde os *cromossomos* mais fortes eram escolhidos. Na reprodução, a fração de cruzamento foi definida na forma padrão em 0,8.

Desse modo, o processo de otimização converge determinando um gráfico de pareto-ótimo, composto por um conjunto de soluções. A escolha da melhor combinação dos parâmetros  $\lambda_k$  se realiza por meio da aplicação do Erro Percentual Global (EPG), escolhendo-se aquela combinação que apresenta o menor valor do EPG. O EPG está definido pela Equação 3.8.

O Erro Percentual Global (EPG) indica o desvio das respostas ótimas da otimização em relação aos ótimos individuais de cada uma das respostas, avaliando a qualidade da solução encontrada na otimização.

## 4.2 Metodologia 2

Esta etapa do projeto tem por objetivo utilizar outra abordagem de classificação com o procedimento de segmentação automático proposto por Dourado Neto (2014). E com os resultados encontrados nessa proposta, realizar uma comparação com os resultados alcançados no classificador da metodologia anterior.

A base de imagens utilizada na Metodologia 2 é igual a base de imagens utilizada na Metodologia 1, porém o procedimento de classificação e os parâmetros de entrada dos classificadores utilizados nas duas metodologias são diferentes.

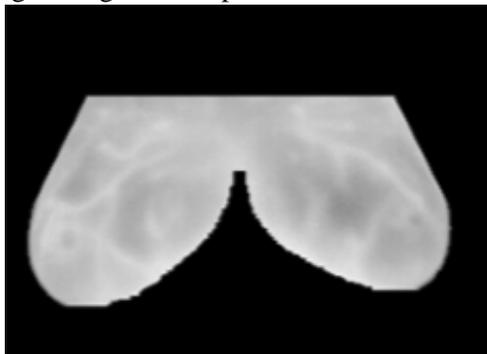
O algoritmo de segmentação e extração de características, desenvolvido por Dourado Neto (2014), foram utilizados, realizando a segmentação das regiões de interesse (ROI) das mamas de forma automática e extraindo 20 características.

O processo de segmentação automática foi desenvolvido numa rotina de Matlab, onde uma matriz de temperatura é inserida no *software* que gera uma imagem em níveis de cinza de onde será realizada a segmentação da região de interesse. Assim como na segmentação manual apresentada por Araújo (2014), no procedimento automático proposto por Dourado Neto (2014), a matriz de temperatura é obtida por meio do *software FLIR QuickReport*, onde esses dados são importados pelo Matlab, formando uma pseudo-imagem de modo que a cada valor de temperatura é atribuído uma cor correspondente. A imagem segmentada é tratada em níveis de cinza, onde temperaturas mais elevadas encontram-se em tons mais claros e temperaturas mais baixas em tons mais escuros.

A segmentação é o procedimento de separação das regiões de interesse das mamas do fundo da imagem das pacientes. O projeto de segmentação automática desenvolvido por Dourado Neto (2014), realiza a segmentação descartando as regiões do pescoço, das axilas e da parte inferior das mamas, determinando os limites superiores e inferiores da região de interesse.

A Figura 4 mostra um exemplo de segmentação automática de mamas realizadas pelo procedimento de Dourado Neto (2014).

Figura 4 – Imagem Segmentada pelo método de Dourado Neto (2014)



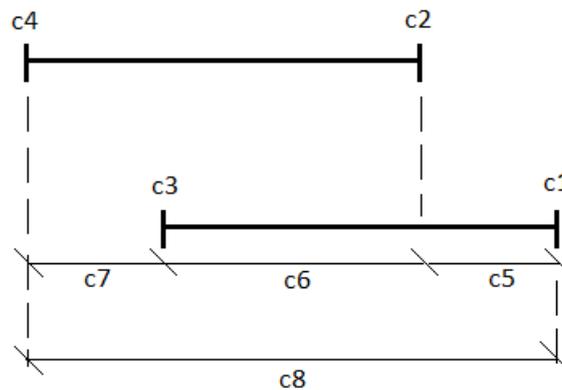
Fonte: DOURADO NETO (2014)

A utilização de segmentação de modo automático ou manual apresenta algumas vantagens e desvantagens quando comparadas entre si. A grande vantagem do uso da segmentação manual consiste na minimização de erros de segmentação, muitas vezes provocados pela assimetria natural entre as mamas. O procedimento facilita a delimitação da área de interesse de cada mama conforme desejado pelo profissional. A desvantagem está no tempo de realização do procedimento, já que a segmentação manual é um processo mais lento, necessitando de mais tempo para que o procedimento de classificação possa ser realizado. Quanto ao método de segmentação automático, a grande vantagem encontra-se na praticidade e rapidez como a segmentação das regiões de interesse (ROI) é realizada.

Realizada a etapa de segmentação automática, o próprio algoritmo desenvolvido por Dourado Neto (2014) executa a extração de características. Essas características são os parâmetros de entrada da etapa de classificação.

Assim como na abordagem de Araújo (2014), o procedimento desenvolvido por Dourado Neto (2014) se fundamentou em medidas estatísticas, como média e desvio-padrão, e intervalares baseadas em diferenças entre as temperaturas máximas e mínimas entre as mamas. Com um total de vinte características extraídas.

Figura 24 – Representação gráfica de algumas características definidas a partir das temperaturas máximas e mínimas da mama esquerda e da mama direita



Fonte: adaptado de DOURADO NETO (2014)

As vinte características foram as seguintes:

$c_1$  = 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;

$$c_5 = c_1 - c_2;$$

$$c_6 = c_2 - c_3;$$

$$c_7 = c_3 - c_4;$$

$$c_8 = c_1 - c_4;$$

$c_9$  = média das temperaturas;

$c_{10}$  = desvio padrão das temperaturas;

Com o objetivo de se evitar a influência de possíveis regiões, fora da região de interesse (ROI), que no processo de segmentação não foram totalmente excluídas, Dourado Neto (2014) criou um critério de robustez baseado nos seguintes tópicos:

- Para a máxima temperatura, se levam em consideração apenas os *pixels* cujas temperaturas são maiores ou iguais aos 8 *pixels* imediatamente vizinhos, não pertencentes a borda da região segmentada;
- Para a mínima temperatura, se levam em consideração apenas os *pixels* cujas temperaturas são menores ou iguais aos 8 *pixels* imediatamente vizinhos, não pertencentes a borda da região segmentada.

Esse critério de robustez foi aplicado a todas as características que vão de 1 a 8. O mesmo procedimento de extração de características, porém sem o critério de robustez, foi realizado para as características que vão de 11 a 18. Desse modo, sem o critério de robustez as demais características são:

$c_{11}$  = máximo entre as temperaturas máximas da mama esquerda e da mama direita;

$c_{12}$  = mínimo entre as temperaturas máximas da mama esquerda e da mama direita;

$c_{13}$  = máximo entre as temperaturas mínimas da mama esquerda e da mama direita;

$c_{14}$  = mínimo entre as temperaturas mínimas da mama esquerda e da mama direita;

$$c_{15} = c_{11} - c_{12};$$

$$c_{16} = c_{12} - c_{13};$$

$$c_{17} = c_{13} - c_{14};$$

$$c_{18} = c_{11} - c_{14};$$

$c_{19}$  = obliquidade (medida de assimetria) do histograma das temperaturas;

$c_{20}$  = curtose do histograma das temperaturas;

As vinte características extraídas foram inseridas como parâmetros de entrada no processo de classificação. Para isso foram utilizados classificadores do *software* WEKA e escolhido aquele que apresentou os melhores resultados quanto à taxa de acerto e ao valor da sensibilidade à Classe Maligno.

Para a classificação, toda a amostra foi dividida em 5 subconjuntos, para a criação do grupo de treinamento. A validação do classificador foi realizada por meio da validação cruzada.

### 4.3 Metodologia 3

A metodologia relativa à última análise deste projeto consiste em avaliar o comportamento e a influência da utilização da técnica de combinação de classificadores, observando os seus resultados quanto a sua eficácia de classificação e comparando com os resultados alcançados pelos classificadores individuais.

Para isso, foram utilizados os dados obtidos no estudo de Vasconcelos (2017), onde duas abordagens de classificação são utilizadas: uma que utiliza um classificador binário (Câncer e Não-Câncer) e outra com o classificador multiclasse (Normal, Benigno, Maligno e Cisto). Para o classificador multiclasse, Vasconcelos (2017) utilizou uma base com um total de 312 imagens termográficas uniformemente distribuídas entre as classes, das quais 233 foram imagens reais coletadas de pacientes com um diagnóstico determinado enquanto que as 79 imagens restantes foram obtidas por meio da criação de vetores sintéticos, criadas com o intuito de balancear a base. Para o classificador binário, a autora utilizou um total de 380 imagens igualmente distribuídas entre as duas classes, das quais 233 foram as mesmas imagens reais coletadas de pacientes com diagnóstico determinado enquanto as outras 147 imagens foram criadas com a técnica de vetores sintéticos para balancear a amostra. A técnica de vetores sintéticos é um procedimento de *input* de dados, onde um vetor sintético consiste na criação de um novo elemento de uma determinada classe, cujas características são baseadas na média das características de três elementos da mesma classe. Essa técnica tem por objetivo aumentar e balancear a base de dados.

O procedimento de segmentação utilizado foi a segmentação automática proposta por Dourado Neto (2014). Quanto à extração de atributos, foram consideradas 20 características, fundamentadas em medidas estatísticas e em medidas intervalares, apresentados na Metodologia 2.

Para a classificação, Vasconcelos (2017) utilizou os classificadores do *software* WEKA, tais como *Naive Bayes*, *Bayes Net*, *Random Forest*, *Multilayer Perceptron*, *Random Tree*, *IBK* e *SMO*, obtendo bons resultados individuais para cada classificador.

No presente trabalho, a metodologia proposta realizou, também no *software* WEKA, a combinação desses e outros classificadores que compõem a biblioteca de classificadores do *software* objetivando alcançar resultados mais satisfatórios, partindo da premissa de que mais de um classificador pode “pensar” e “decidir” melhor uma classificação do que quando apenas um único classificador é utilizado.

Para isso, esta dissertação usou a mesma base usada no projeto de Vasconcelos (2017), extraindo as mesmas 20 características e, a partir de um arquivo *.arff* criado com esses dados e inseridos no WEKA, foi realizada a classificação combinada utilizando duas abordagens de combinação: *Voting* e *Stacking*. Estes dois métodos citados são combinadores de classificadores heterogêneos, que permitem que diferentes tipos de classificadores sejam combinados de modo que o procedimento de classificação final seja realizado levando em consideração a decisão de cada classificador base.

Os parâmetros de análise e comparação do procedimento de combinação de classificadores foram a taxa de acerto do classificador e o valor da sensibilidade à Classe Maligno, já que a presença de falsos negativos em relação a esta classe compromete o diagnóstico precoce do câncer de mama. Além destes parâmetros, o coeficiente Kappa também será analisado bem como as matrizes de confusão, que são parâmetros que caracterizam a eficácia do classificador.

## 5 RESULTADOS E DISCUSSÃO

Neste capítulo são mostrados os resultados alcançados com a aplicação das metodologias propostas e esplanadas no capítulo anterior. Os resultados foram avaliados quanto à eficácia dos métodos citados, analisando os melhores métodos para se aplicar no processo de classificação de imagens termográficas para o diagnóstico de anomalias mamárias.

A primeira análise quanto aos métodos citados, consistiu em avaliar a eficácia do processo de otimização no procedimento de escolha da melhor combinação dos parâmetros de peso  $\lambda_k$  no classificador desenvolvido por Araújo (2014), observando em quanto o novo procedimento beneficia o processo de classificação, tanto quanto à diminuição de tempo de processamento que a otimização possibilita, quanto à eficácia nos resultados de sensibilidade à Classe Maligno e da taxa de acerto do classificador.

A análise seguinte incluiu um procedimento de classificação, baseado no projeto desenvolvido por Dourado Neto (2014), utilizando a segmentação automática. Para isso, foram obtidos resultados de classificação utilizando classificadores do WEKA. Os resultados obtidos foram comparados com os resultados apresentados no classificador otimizado proposto na Metodologia 1. O propósito da comparação é avaliar se o novo método proposto na Metodologia 1 apresenta bons resultados de classificação quando comparados a outros modelos de classificação.

Por fim, foi apresentado um estudo quanto à combinação de classificadores estatísticos, mostrando os resultados que este tipo de técnica alcança, quanto à eficácia de um classificador. Em seguida, os resultados obtidos da combinação dos classificadores são comparados com os resultados da classificação individual de cada classificador. Este procedimento foi realizado tanto na metodologia que utiliza quatro classes, quanto no procedimento de classificação binário (Câncer/Não-Câncer), utilizando a base de dados de Vasconcelos (2017), a fim de se observar se esta técnica influencia positivamente ou não nos resultados de classificação.

### 5.1 Resultados obtidos com a Metodologia 1

Araújo (2014) desenvolveu um classificador estatístico de três classes (Maligno, Benigno e Cisto) para classificar anomalias mamárias. Um dos objetivos desta dissertação foi a ampliação desse classificador, com o incremento de mais uma classe, a Classe Normal. Deste modo, o algoritmo original do programa foi modificado para que esta ampliação pudesse ser realizada. Além da ampliação das classes analisadas, o processo de classificação também foi alterado quanto à base de dados de entrada. Em seu classificador, Araújo (2014) realizou uma classificação com uma base de 50 imagens

distribuídas para as três classes utilizadas. Neste projeto, a quantidade de imagens foi de 87 imagens distribuídas para as quatro classes ou de 71 imagens distribuídas para as três classes utilizadas no classificador original de Araújo (2014). Um procedimento de otimização na classificação das imagens termográficas de mamas foi proposto objetivando um processamento mais rápido de classificação, sem perder a eficácia do classificador.

Feitas essas modificações, o classificador foi utilizado com o objetivo de observar o comportamento e a influência de tais mudanças. Para isso, foi realizado o procedimento iterativo com o objetivo de se determinar a melhor combinação dos parâmetros de peso  $\lambda_k$ , correspondente às quatro classes. Inicialmente, a iteração foi realizada no classificador em sua forma original desenvolvido por Araújo (2014) (apenas com a modificação da quantidade de classes de três para quatro classes), com os valores dos  $\lambda_k$ , incrementais de 0,1, partindo de 0 até 1, de modo que cada parâmetro  $\lambda_k$  foi testado com 11 valores diferentes (0; 0,1; 0,2; ... ;1). Desse modo, combinando os quatro parâmetros de peso  $\lambda_k$ , foram realizadas  $11^4$  iterações, totalizando 14.641 iterações. A única inconveniência desse procedimento é o custo computacional e o tempo de análise. Os resultados da classificação que obtiveram os melhores valores estão apresentados na Tabela 5.

Tabela 5 – Resultado de classificação com a base contendo 87 imagens utilizando o classificador de Araújo (2014) ampliado para quatro classes

Resultado com 4 classes							
base de imagens	Sensibilidade ao Maligno	acertos	% acerto	Classe Benigno	Classe Maligno	Classe Cisto	Classe Normal
87	96,30%	64	73,56%	22	27	22	16

Tabela 6 – Combinações dos parâmetros de peso  $\lambda_k$  que alcançaram os melhores resultados de classificação, utilizando o classificador proposto por Araújo (2014), ampliado para quatro classes

Taxa de acerto	Sensibilidade ao Maligno	$\lambda_1$	$\lambda_2$	$\lambda_3$	$\lambda_4$
73,56%	96,30%	0,3	0,2	0,6	0,6
73,56%	96,30%	0,4	0,3	0,7	0,7
73,56%	96,30%	0,4	0,3	0,8	0,7
73,56%	96,30%	0,4	0,4	0,7	0,7
73,56%	96,30%	0,4	0,4	0,8	0,7
73,56%	96,30%	0,4	0,4	0,9	0,7
73,56%	96,30%	0,4	0,4	1	0,7
73,56%	96,30%	0,6	0,4	0,9	0,8
73,56%	96,30%	0,6	0,5	0,9	0,8
73,56%	96,30%	0,7	0,5	1	0,9
73,56%	96,30%	0,7	0,6	1	0,9

onde,  $\lambda_1$  corresponde ao parâmetro de peso dado a cada limite do intervalo *Inf* e *Sup* na definição da matriz de covariância parametrizada para a Classe Benigno;

$\lambda_2$  corresponde ao parâmetro de peso dado a cada limite do intervalo *Inf* e *Sup* na definição da matriz de covariância parametrizada para a Classe Maligno;

$\lambda_3$  corresponde ao parâmetro de peso dado a cada limite do intervalo *Inf* e *Sup* na definição da matriz de covariância parametrizada para a Classe Cisto;

$\lambda_4$  corresponde ao parâmetro de peso dado a cada limite do intervalo *Inf* e *Sup* na definição da matriz de covariância parametrizada para a Classe Normal;

Para se obter uma matriz de confusão qualquer, dentre essas combinações dos parâmetros  $\lambda_k$ , escolheu-se a primeira combinação dos  $\lambda_k$  da Tabela 5 ( $\lambda_1 = 0,3$ ;  $\lambda_2 = 0,2$ ;  $\lambda_3 = 0,6$ ;  $\lambda_4 = 0,6$ ), obtendo-se a seguinte matriz de confusão, onde são apresentados os resultados da classificação para cada classe (Figura 25).

Figura 25 – Matriz de confusão da classificação utilizando o classificador de Araújo (2014) ampliado para quatro classes, com a seguinte combinação dos parâmetros de peso  $\lambda_k$ :  $\lambda_1 = 0,3$ ;  $\lambda_2 = 0,2$ ;  $\lambda_3 = 0,6$ ;  $\lambda_4 = 0,6$

		CLASSIFICAÇÃO				Total de amostras
		Maligno	Benigno	Cisto	Normal	
VERDADEIRO	Maligno	17	3	0	2	22
	Benigno	1	26	0	0	27
	Cisto	4	4	13	1	22
	Normal	6	1	2	7	16
Total:					87	

Com base nos resultados mostrados, onde foram obtidas uma taxa de acerto de 73,56% e uma sensibilidade à Classe Maligno de 96,30%, pode-se considerar que esse procedimento de classificação de mamas para quatro classes (Maligno, Benigno, Cisto e Normal) apresentou bons resultados quanto à sua acurácia. Isto qualifica o procedimento de classificação de imagens termográficas de mamas, ampliando a técnica com valores que a torna viável e eficaz em aplicações médicas, sendo apresentada como mais uma ferramenta no auxílio ao diagnóstico precoce do câncer de mama.

Como parte do estudo, foi analisada também, a influência do aumento da base de dados nos resultados. Para isso, foi utilizado o programa desenvolvido por Araújo (2014) em sua forma original, com três classes para classificação (Maligno, Benigno e Cisto). Em seu projeto, Araújo (2014) utilizou 50 imagens distribuídas nas três classes. Na presente dissertação, essa base foi aumentada para 71 imagens distribuídas para as três

classes e realizada a classificação. Em seus estudos, Araújo (2014) utilizando 50 imagens distribuídas entre as três classes alcançou como resultado uma taxa de acerto de 84% e uma sensibilidade à Classe Maligno de 93%. Com o aumento da base para 71 imagens, os resultados alcançados estão mostrados na Tabela 7.

Tabela 7 – Resultado de classificação com a base contendo 71 imagens utilizando o classificador de Araújo (2014) em sua forma original contendo três classes

Resultado com 3 classes						
Nº de imagens	Sensibilidade ao Maligno	Acerto	% acerto	Classe Benigno	Classe Maligno	Classe Cisto
71	96,30%	59	83,10%	22	27	23
50	93,00%	42	84,00%	19	14	17

Tabela 8 – Combinações dos parâmetros de peso  $\lambda_k$  que alcançaram os melhores resultados de classificação, utilizando o classificador de Araújo (2014) em sua forma original para três classes, com uma base de 71 imagens

Acerto	Taxa de acerto	Sensibilidade ao Maligno	$\lambda_1$	$\lambda_2$	$\lambda_3$
59	83,10%	96,30%	0,4	0,3	0,4
59	83,10%	96,30%	0,7	0,5	0,6

Como é mostrado nas Tabelas 7 e 8, para a base de 71 imagens, a melhor taxa de acerto encontrada foi de 83,10% com uma sensibilidade à Classe Maligno de 96,30%. Comparando esses resultados àqueles encontrados por Araújo (2014) com a sua base de dados, pode-se concluir que o aumento da base em 21 imagens (representando um aumento de 42% em imagens) provocou uma pequena influência nos resultados. Houve um pequeno decréscimo na taxa de acerto e um aumento de 3% na sensibilidade à Classe Maligno.

### 5.1.1 Otimização do classificador para encontrar os parâmetros de peso $\lambda_k$

Após a análise do aumento das classes do classificador e do aumento da base usada, foi realizado um estudo com objetivo de deixar o processo de classificação mais rápido sem perder a sua eficácia quanto às taxas de acerto e à sensibilidade à Classe Maligno, otimizando o processo de escolha da combinação dos parâmetros de peso  $\lambda_k$ .

O processo de otimização consiste em encontrar a melhor combinação dos parâmetros  $\lambda_k$  correspondentes a cada classe  $C_k$  que retorne os maiores valores da taxa

de acerto do classificador, juntamente com os maiores valores da sensibilidade à Classe Maligno.

Como foi explicado na metodologia, o procedimento foi iniciado com dois processos iterativos do classificador, de modo que os dados da classificação são importados pelo *software* Minitab, que realiza uma modelagem por um processo de regressão múltipla e que consiste em criar um modelo da taxa de acerto em função dos  $\lambda_k$ . A outra modelagem por regressão múltipla cria uma função da sensibilidade à Classe Maligno em função dos  $\lambda_k$ .

Outros procedimentos de regressão podem ser realizados modelando funções de outros parâmetros desejados, tais como sensibilidade a qualquer outra classe ou especificidade de qualquer classe, criando várias formulações que poderão ser importadas pelo otimizador de múltiplas funções.

Foram escolhidas essas duas modelagens por regressão, das funções em relação à taxa de acerto e à sensibilidade à Classe Maligno, uma vez que a taxa de acerto qualifica a acurácia do classificador e a sensibilidade à Classe Maligno é um parâmetro, onde a minimização de falsos negativos com respeito a esta classe, qualifica o diagnóstico precoce do câncer de mama.

Para avaliar se o modelo encontrado por meio da regressão múltipla apresenta uma significância estatística, foi necessário avaliar a qualidade do ajuste dos modelos formulados por meio do coeficiente de determinação ajustado ( $R_a^2$ ), além da importância de cada coeficiente da fórmula através dos parâmetros *p-values*. Os resultados encontrados para os dois modelos criados, analisando estes parâmetros, foram de um coeficiente de determinação ajustado ( $R_a^2$ ) para a modelagem da função da taxa de acerto num valor de 95,70% e, para a modelagem da função de sensibilidade, o coeficiente de determinação ajustado ( $R_a^2$ ) foi de 96,38%. Ou seja, ambas as modelagens apresentam uma significância estatística de acordo com os dados. Todos os termos dos coeficientes que apresentaram um valor de *p-value* superior a 5% foram desconsiderados, já que para que o coeficiente apresente um valor significativo, o valor do *p-value* deve ser menor do que 5%.

Sendo assim, os dois modelos de funções objetivo, das taxas de acerto e da sensibilidade à Classe Maligno, determinados com o auxílio do *software* Minitab em função dos parâmetros de peso  $\lambda_k$ , foram:

$$\begin{aligned} \text{Taxa de acerto} = & 0,81584 + 0,39873*\lambda_1 + 0,19889*\lambda_2 + 0,18952*\lambda_3 + 0,45841*\lambda_4 - \\ & 3,4063*\lambda_1^2 - 1,98095*\lambda_2^2 - 2,8444*\lambda_3^2 - 1,83*\lambda_4^2 + 1,4*\lambda_1*\lambda_2 + 0,1857*\lambda_1*\lambda_3 + \\ & 3,52698*\lambda_1*\lambda_4 - 0,3508*\lambda_2*\lambda_3 - 0,81746*\lambda_2*\lambda_4 + 1,1444*\lambda_3*\lambda_4 + 5,6857*\lambda_1^3 + \\ & 4,557*\lambda_2^3 + 7,3127*\lambda_3^3 + 1,0746*\lambda_4^3 - 0,0476*\lambda_1*\lambda_2^2 - 0,0619*\lambda_1*\lambda_3^2 - \\ & 4,24127*\lambda_1*\lambda_4^2 - 4,06*\lambda_1^2*\lambda_2 - 0,0159*\lambda_1^2*\lambda_3 - 2,7762*\lambda_1^2*\lambda_4 + \\ & 0,5349*\lambda_2*\lambda_3^2 + 1,3873*\lambda_2*\lambda_4^2 + 0,190476*\lambda_2^2*\lambda_3 + 1,8429*\lambda_2^2*\lambda_4 - \end{aligned}$$

$$\begin{aligned}
& 0,8127*\lambda^2*\lambda^4 - 1,3095*\lambda^3*\lambda^4^2 - 3,5349*\lambda^1^4 - 5,013*\lambda^2^4 - 7,5476*\lambda^3^4 + \\
& 1,9254*\lambda^4^4 + 1,20794*\lambda^1*\lambda^2^3 - 1,046*\lambda^1*\lambda^3^3 - 0,37143*\lambda^1*\lambda^4^3 + \\
& 4,4984*\lambda^1^3*\lambda^2 + 0,26825*\lambda^1^3*\lambda^3 - 2,8556*\lambda^1^3*\lambda^4 + 0,35397*\lambda^2*\lambda^3^3 - \\
& 0,99*\lambda^2*\lambda^4^3 - 0,1317*\lambda^2^3*\lambda^3 - 2,933*\lambda^2^3*\lambda^4 - 0,10159*\lambda^3*\lambda^4^3 + \\
& 0,14286*\lambda^3^3*\lambda^4 - 0,45397*\lambda^1^2*\lambda^2^2 + 0,9349*\lambda^1^2*\lambda^3^2 + 6,808*\lambda^1^2*\lambda^4^2 - \\
& 0,39365*\lambda^2^2*\lambda^3^2 - 0,3778*\lambda^2^2*\lambda^4^2 + 1,433*\lambda^3^2*\lambda^4^2 + 0,6746*\lambda^1^5 + \\
& 2,03*\lambda^2^5 + 2,727*\lambda^3^5 - 1,7*\lambda^4^5 - 1,122*\lambda^1*\lambda^2^4 + 1,108*\lambda^1*\lambda^3^4 + \\
& 1,3873*\lambda^1*\lambda^4^4 - 1,5873*\lambda^1^4*\lambda^2 - 0,60635*\lambda^1^4*\lambda^3 + 2,752*\lambda^1^4*\lambda^4 - \\
& 0,635*\lambda^2*\lambda^3^4 + 0,0857*\lambda^2*\lambda^4^4 + 0,281*\lambda^2^4*\lambda^3 + 1,6*\lambda^2^4*\lambda^4 + 0,841*\lambda^3*\lambda^4^4 - \\
& 0,354*\lambda^3^4*\lambda^4 + 0,73*\lambda^1^2*\lambda^2^3 - 1,103*\lambda^1^2*\lambda^3^3 - 1,6794*\lambda^1^2*\lambda^4^3 - \\
& 0,376*\lambda^1^3*\lambda^2^2 + 0,446*\lambda^1^3*\lambda^3^2 - 2,3476*\lambda^1^3*\lambda^4^2 + 0,665*\lambda^2^2*\lambda^3^3 + \\
& 0,43*\lambda^2^2*\lambda^4^3 - 0,5175*\lambda^2^3*\lambda^3^2 - 0,2444*\lambda^2^3*\lambda^4^2 - 1,63*\lambda^3^2*\lambda^4^3 + \\
& 0,806*\lambda^3^3*\lambda^4^2
\end{aligned}$$

(5.1)

$$\begin{aligned}
& \text{Sensibilidade ao maligno} = 0,61791 + 0,5249*\lambda^1 + 0,3845*\lambda^2 + 0,2593*\lambda^3 + 1,1874*\lambda^4 \\
& - 3,400*\lambda^1^2 - 2,845*\lambda^2^2 - 1,184*\lambda^3^2 - 5,007*\lambda^4^2 + 1,381*\lambda^1*\lambda^2 + 0,361*\lambda^1*\lambda^3 + \\
& 4,907*\lambda^1*\lambda^4 - 0,723*\lambda^2*\lambda^3 - 2,438*\lambda^2*\lambda^4 + 0,165*\lambda^3*\lambda^4 + 7,10*\lambda^1^3 + 6,19*\lambda^2^3 + \\
& 2,37*\lambda^3^3 + 7,96*\lambda^4^3 - 0,083*\lambda^1*\lambda^2^2 - 0,046*\lambda^1*\lambda^3^2 - 5,453*\lambda^1*\lambda^4^2 - \\
& 4,339*\lambda^1^2*\lambda^2 - 0,176*\lambda^1^2*\lambda^3 - 7,350*\lambda^1^2*\lambda^4 + 1,294*\lambda^2*\lambda^3^2 + 5,469*\lambda^2*\lambda^4^2 - \\
& 0,219*\lambda^2^2*\lambda^3 + 3,312*\lambda^2^2*\lambda^4 - 0,080*\lambda^3^2*\lambda^4 + 0,177*\lambda^3*\lambda^4^2 - 6,08*\lambda^1^4 - \\
& 6,07*\lambda^2^4 - 2,73*\lambda^3^4 - 5,37*\lambda^4^4 + 1,280*\lambda^1*\lambda^2^3 - 0,621*\lambda^1*\lambda^3^3 + 1,710*\lambda^1*\lambda^4^3 \\
& + 5,40*\lambda^1^3*\lambda^2 - 0,684*\lambda^1^3*\lambda^3 + 3,920*\lambda^1^3*\lambda^4 + 0,981*\lambda^2*\lambda^3^3 - 5,082*\lambda^2*\lambda^4^3 \\
& + 0,960*\lambda^2^3*\lambda^3 - 5,100*\lambda^2^3*\lambda^4 - 0,623*\lambda^3*\lambda^4^3 + 0,417*\lambda^3^3*\lambda^4 - \\
& 0,812*\lambda^1^2*\lambda^2^2 + 0,803*\lambda^1^2*\lambda^3^2 + 6,440*\lambda^1^2*\lambda^4^2 - 1,471*\lambda^2^2*\lambda^3^2 - \\
& 1,422*\lambda^2^2*\lambda^4^2 - 0,094*\lambda^3^2*\lambda^4^2 + 1,843*\lambda^1^5 + 2,045*\lambda^2^5 + 1,252*\lambda^3^5 + \\
& 1,275*\lambda^4^5 - 0,591*\lambda^1*\lambda^2^4 + 0,276*\lambda^1*\lambda^3^4 + 0,125*\lambda^1*\lambda^4^4 - 2,262*\lambda^1^4*\lambda^2 + \\
& 0,532*\lambda^1^4*\lambda^3 - 0,512*\lambda^1^4*\lambda^4 - 1,542*\lambda^2*\lambda^3^4 + 1,352*\lambda^2*\lambda^4^4 - 0,061*\lambda^2^4*\lambda^3 + \\
& 3,097*\lambda^2^4*\lambda^4 + 0,411*\lambda^3*\lambda^4^4 - 0,378*\lambda^3^4*\lambda^4 - 0,143*\lambda^1^2*\lambda^2^3 + \\
& 0,023*\lambda^1^2*\lambda^3^3 - 1,466*\lambda^1^2*\lambda^4^3 + 0,429*\lambda^1^3*\lambda^2^2 - 0,424*\lambda^1^3*\lambda^3^2 - \\
& 2,081*\lambda^1^3*\lambda^4^2 + 1,719*\lambda^2^2*\lambda^3^3 + 1,557*\lambda^2^2*\lambda^4^3 - 0,943*\lambda^2^3*\lambda^3^2 - \\
& 0,866*\lambda^2^3*\lambda^4^2 - 0,152*\lambda^3^2*\lambda^4^3 + 0,233*\lambda^3^3*\lambda^4^2
\end{aligned}$$

(5.2)

Obtidas as funções objetivo por meio da regressão, estas foram inseridas no processo de otimização multiobjetivo. A ferramenta de otimização que foi utilizada faz parte do pacote de *Optimization Tools* pertencente à plataforma Matlab. A função de otimização utilizada foi a função *@gamultiobj* que é uma ferramenta de otimização computacional multiobjetivo que utiliza a técnica do Algoritmo Genético. As duas

funções objetivo modeladas foram inseridas no *software* de otimização além dos limites dos valores dos objetivos, que têm 0 como limite inferior e 1 como limite superior.

Os parâmetros de Algoritmos Genéticos, tais como população, seleção, reprodução, mutação, cruzamento, critério de parada foram mantidos na forma padrão (*default*) como apresentadas no *software*. O tipo de população é por duplo vetor, a seleção é por torneio e a taxa de cruzamento é a padrão em 0,8.

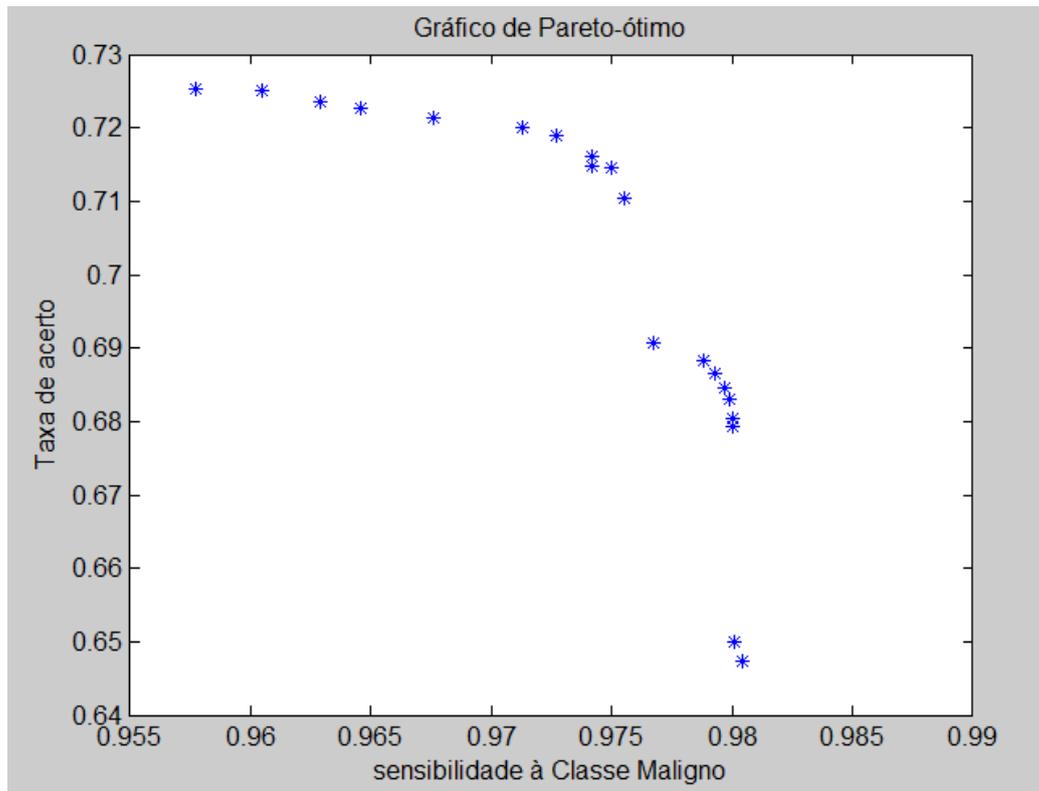
Realizado esse procedimento de otimização, a resposta contendo os valores dos parâmetros  $\lambda_k$ , juntamente com o valor da Taxa de Acerto e da sensibilidade à Classe Maligno está apresentada na Tabela 9.

Tabela 9 – Valores do procedimento de otimização multiobjetivo apresentando as melhores combinações dos parâmetros de peso  $\lambda_k$

Taxa de Acerto	Sensibilidade ao Maligno	$\lambda_1$	$\lambda_2$	$\lambda_3$	$\lambda_4$
67,92%	98,00%	0,58325	0,064915	0,63829	0,5164
71,46%	97,50%	0,44538	0,38469	0,88436	0,86714
72,13%	96,76%	0,45043	0,49248	0,92249	0,87807
68,66%	97,93%	0,51283	0,071978	0,64275	0,5026
64,99%	98,01%	0,99936	0,089565	0,68689	0,58677
72,00%	97,13%	0,44585	0,46185	0,882	0,88344
72,54%	95,77%	0,44188	0,5334	0,99997	0,88671
71,61%	97,42%	0,45402	0,4136	0,86499	0,85604
72,35%	96,29%	0,44039	0,5127	0,97243	0,88666
68,30%	97,99%	0,54746	0,065039	0,63852	0,50471
72,50%	96,05%	0,44432	0,51887	0,99486	0,88671
68,82%	97,88%	0,50029	0,077595	0,65862	0,51387
71,05%	97,55%	0,45719	0,34861	0,85756	0,84902
68,45%	97,97%	0,53258	0,068609	0,63908	0,50568
69,08%	97,67%	0,48499	0,11155	0,70555	0,51938
72,26%	96,46%	0,44321	0,50805	0,95281	0,88624
71,04%	97,55%	0,46023	0,34881	0,85197	0,85019
71,89%	97,27%	0,44756	0,44381	0,88112	0,87409
71,48%	97,42%	0,44911	0,38721	0,91735	0,86892
68,04%	98,00%	0,574	0,068902	0,63993	0,5132
64,73%	98,04%	0,9998	0,083351	0,65435	0,5986

O gráfico de pareto-ótimo com os resultados destas duas funções objetivo correlacionadas entre si está apresentado na Figura 26.

Figura 26 – Gráfico de pareto-ótimo das funções objetivo Taxa de acerto e Sensibilidade à Classe Maligno



Com os valores de pareto-ótimo apresentados, o objetivo é decidir qual destes pontos apresenta o melhor resultado, conseqüentemente os que têm a melhor combinação dos parâmetros de peso  $\lambda_k$ . Para isso, será utilizado o critério de decisão baseado no Erro Percentual Global apresentado na metodologia. O critério é apresentado pela seguinte equação:

$$EPG = \sum_{i=1}^m \left| \frac{y_i^*}{f_i(x_i^*)} - 1 \right| \quad (3.8)$$

onde,  $y_i^*$  são os valores das respostas pareto-ótimas, e

$f_i(x_i^*)$  são os alvos definidos (valores das otimizações individuais).

Os valores das respostas pareto-ótimas já foram obtidos. Há a necessidade de se determinar os valores ótimos das funções objetivo individuais. Para isso foi feito um processo de otimização mono-objetivo simples, obtendo os valores ótimos de cada função objetivo. O procedimento foi realizado utilizando a mesma função de otimização por

Algoritmo Genético, pertencente ao pacote *Optimization Toolbox* do Matlab. A otimização tem como saída uma única combinação dos parâmetros de peso  $\lambda_k$  que são inseridos no classificador para se obter os resultados da classificação desejado. Esses resultados são o valor máximo da taxa de acerto e o valor máximo da sensibilidade à Classe Maligno. Dois procedimentos foram realizados para se encontrar os valores máximos, pertencentes às duas funções objetivo.

Os valores ótimos das duas funções objetivo foram 72,41% de valor da taxa de acerto e 96,30% de sensibilidade à Classe Maligno. Desse modo, os dados são colocados na fórmula do EPG, e aquele que tiver o menor valor do Erro Percentual Global será considerado o melhor resultado da otimização e conseqüentemente a melhor combinação dos parâmetros  $\lambda_k$ .

Dessa forma, aplicando o EPG, a melhor combinação dos parâmetros de peso  $\lambda_k$  encontrada que apresentou o menor Erro Percentual Global está mostrada na Tabela 10.

Tabela 10 – Melhor combinação dos parâmetros de peso  $\lambda_k$ , encontrados por meio do processo de otimização e do EPG

$\lambda_1$	$\lambda_2$	$\lambda_3$	$\lambda_4$
<b>0,44039</b>	<b>0,5127</b>	<b>0,97243</b>	<b>0,88666</b>

Para validar este teste, a combinação obtida para os valores dos parâmetros  $\lambda_k$  foi inserida no classificador utilizado e o processo de classificação com estes parâmetros apresentou o resultado da Tabela 11, a seguir.

Tabela 11 – Resultado da classificação baseado na combinação dos parâmetros de peso  $\lambda_k$  encontrados por meio da otimização

Acerto	Taxa de Acerto	Sensibilidade ao Maligno	$\lambda_1$	$\lambda_2$	$\lambda_3$	$\lambda_4$
63	72,41%	96,30%	0,44039	0,5127	0,97243	0,88666

Para confirmar a eficácia do processo de otimização, o classificador foi utilizado na sua maneira original, sem o processo de otimização, com o incremento dos valores dos parâmetros  $\lambda_k$  de 0,1 em 0,1, conforme sugerido na forma original apresentado por Araújo (2014). Os melhores resultados alcançados dessa maneira encontram-se na Tabela 6.

Tabela 6 – Combinações dos parâmetros de peso  $\lambda_k$  que alcançaram os melhores resultados de classificação, utilizando o classificador proposto por Araújo (2014), ampliado para quatro classes

Taxa de Acerto	Sensibilidade ao Maligno	$\lambda_1$	$\lambda_2$	$\lambda_3$	$\lambda_4$
73,56%	96,30%	0,3	0,2	0,6	0,6
73,56%	96,30%	0,4	0,3	0,7	0,7
73,56%	96,30%	0,4	0,3	0,8	0,7
73,56%	96,30%	0,4	0,4	0,7	0,7
73,56%	96,30%	0,4	0,4	0,8	0,7
73,56%	96,30%	0,4	0,4	0,9	0,7
73,56%	96,30%	0,4	0,4	1	0,7
73,56%	96,30%	0,6	0,4	0,9	0,8
73,56%	96,30%	0,6	0,5	0,9	0,8
73,56%	96,30%	0,7	0,5	1	0,9
73,56%	96,30%	0,7	0,6	1	0,9

O que mostra que os melhores resultados alcançados obtiveram uma taxa de acerto de 73,56% e uma taxa de sensibilidade à Classe Maligno de 96,30%. Comparando os resultados do classificador original com os resultados da classificação com otimização, pode-se observar que o procedimento de otimização alcançou o mesmo valor de sensibilidade à Classe Maligno e um valor de taxa de acerto de 72,41%, um valor bastante próximo da taxa de acerto pela classificação sem otimização que foi de 73,56%, o que mostra que o processo de otimização é um procedimento eficaz quanto aos resultados esperados.

O grande ganho da técnica de otimização se deu com a diminuição do tempo computacional para a classificação das imagens termográficas. Para se ter uma ideia, o procedimento de classificação que usa o classificador, aplicado às quatro classes, na sua forma original, realiza um total de  $11^4$  iterações totalizando 14641 iterações. Este procedimento foi realizado para a base de dados utilizada de 87 imagens e totalizou um tempo de 26h13min em um computador do modelo Acer, com processador do tipo Intel Core i5-3337U 1,8 GHz com Turbo Boost de 2,7 GHz, com uma memória de 8 Gb DDR3, com a versão Windows 8, 64 Bits.

Ao se utilizar a classificação com a proposta de otimização, onde foram realizados dois processos iterativos, e para um computador com as mesmas configurações citadas acima, o processamento total resultou em um tempo de 4h35min, ou seja, com um procedimento de classificação que requer um tempo 82% menor do que o tempo de classificação utilizando o classificador na sua forma original apresentado acima. Um resultado bastante eficaz foi obtido quando comparado ao melhor resultado alcançado com o classificador em sua forma original. Conclui-se então que o procedimento de otimização proposto é uma excelente alternativa para a classificação de imagens

termográficas de uma maneira mais rápida, encontrando uma combinação dos parâmetros  $\lambda_k$  que apresenta bons resultados de classificação.

## 5.2 Resultados obtidos com a Metodologia 2

Para comparar os resultados obtidos através da Metodologia 1, foi realizada uma outra metodologia de classificação, baseado na segmentação automática proposto por Dourado Neto (2014), que utilizou o *software* WEKA para a classificação.

Seguindo o procedimento metodológico apresentado no capítulo anterior, com a realização da segmentação de maneira automática e extraíndo vinte características baseadas em métodos estatísticos e intervalares, foi criado um arquivo *.arff* e inserindo estes dados no *software* WEKA para realizar a classificação das imagens termográficas utilizando a biblioteca de classificadores do *software*. Os melhores resultados foram obtidos utilizando os classificadores *Naive Bayes*, *SMO*, *SimpleLogistic*, *IBK* e *LMT*.

Toda a amostra de dados foi dividida em cinco subconjuntos utilizados como grupo de treinamento do classificador. O teste do classificador foi realizado por meio de validação cruzada.

Com base nesses critérios, diversos classificadores foram utilizados para classificar esta base. Nesta situação, foram considerados os melhores resultados aqueles que: apresentaram as maiores taxas de acerto do classificador; os maiores valores de sensibilidade à Classe Maligna, visto que a presença de falsos negativos em relação a esta classe compromete o diagnóstico precoce do câncer de mama; e os melhores resultados do coeficiente Kappa. Os resultados estão apresentados na Tabela 12.

Tabela 12 – Resultados da classificação multiclasse utilizando classificadores do WEKA

Classificador	Taxa de acerto	Sensibilidade	Especificidade	Acertos Maligno	Acertos Benigno	Acertos Cisto	Acertos Normal	Kappa
NaiveBayes	43,68%	77,77%	58,62%	77,77%	13,64%	36,36%	37,50%	0,2385
SMO	50,57%	74,07%	66,67%	74,07%	36,36%	40,91%	43,75%	0,328
SimpleLogistic	50,57%	74,07%	66,67%	74,07%	45,45%	40,91%	31,25%	0,3273
Ibk (KNN)	47,13%	70,37%	70,97%	70,37%	22,72%	40,91%	50,00%	0,2883
<b>LMT</b>	<b>55,17%</b>	<b>74,07%</b>	<b>80,00%</b>	<b>74,07%</b>	<b>50,00%</b>	<b>50,00%</b>	<b>37,50%</b>	<b>0,3945</b>

A seguir apresentam-se as matrizes de confusão correspondentes a essas classificações (Figura 27).

Figura 27 – Matrizes de confusão da classificação multiclasse através do WEKA

CLASSIFICAÇÃO NAIVEBAYES

		Maligno	Benigno	Cisto	Normal	Total de amostras
VERDADEIRO	Maligno	21	1	3	2	27
	Benigno	2	3	10	7	22
	Cisto	6	5	8	3	22
	Normal	4	3	3	6	16
					Total:	87

CLASSIFICAÇÃO SMO

		Maligno	Benigno	Cisto	Normal	Total de amostras
VERDADEIRO	Maligno	20	0	6	1	27
	Benigno	4	8	7	3	22
	Cisto	5	7	9	1	22
	Normal	3	5	1	7	16
					Total:	87

CLASSIFICAÇÃO SIMPLELOGISTIC

		Maligno	Benigno	Cisto	Normal	Total de amostras
VERDADEIRO	Maligno	20	0	5	2	27
	Benigno	3	10	6	3	22
	Cisto	4	8	9	1	22
	Normal	5	4	2	5	16
					Total:	87

CLASSIFICAÇÃO IBK

		Maligno	Benigno	Cisto	Normal	Total de amostras
VERDADEIRO	Maligno	19	2	2	4	27
	Benigno	3	5	9	5	22
	Cisto	5	7	9	1	22
	Normal	1	4	3	8	16
					Total:	87

		CLASSIFICAÇÃO LMT				Total de amostras
		Maligno	Benigno	Cisto	Normal	
VERDADEIRO	Maligno	20	0	5	2	27
	Benigno	2	11	4	5	22
	Cisto	2	8	11	1	22
	Normal	3	4	3	6	16
Total:					87	

Todos os classificadores citados foram utilizados na sua forma padrão (*Default*) como apresentado no *software* WEKA, exceto o classificador SMO, onde foi utilizada a função *Kernel* polinomial de grau 3, já que com esta configuração foi alcançado o melhor resultado. Desse modo, com base nos resultados apresentados, o classificador que obteve os melhores resultados foi o classificador LMT. Apresentando uma taxa de acerto de 55,17%, um valor de sensibilidade à Classe Maligno de 74,07% e um coeficiente Kappa de 0,3945, que apresenta uma concordância razoável ao classificador.

Comparando o resultado dessa classificação por meio da segmentação automática e utilizando o classificador LMT do *software* WEKA, com o procedimento de classificação proposto na Metodologia 1, que realiza procedimentos iterativos e otimização para encontrar a melhor combinação dos parâmetros de peso  $\lambda_k$ . Pode-se concluir que o procedimento de classificação proposto na Metodologia 1, alcançou resultados muito satisfatórios com elevada taxa de sensibilidade à Classe Maligno além de um resultado de taxa de acerto consideravelmente maior, com quase 20% mais elevado em relação à taxa de acerto da Metodologia 2. Através da Tabela 13, pode-se comparar os resultados das classificações.

Tabela 13 – Comparação dos processos de classificação

Procedimento de classificação	Resultado com 4 classes				
	base de imagens	acertos	% acerto	Sensibilidade ao Maligno	Especificidade
Metodologia 1	87	64	72,41%	96,30%	86,67%
Metodologia 2	87	48	55,17%	74,07%	80,00%

### 5.3 Resultados obtidos com a Metodologia 3

O processo de combinação de classificadores de quatro classes utilizou uma base de amostra de Vasconcelos (2017). Essa base contém 312 imagens, das quais 233 foram imagens propriamente ditas coletadas de pacientes com diagnósticos distribuídos pelas quatro classes (Maligno, Benigno, Cisto e Normal) e outras 79 imagens foram obtidas por meio da criação de vetores sintéticos, criadas com o intuito de balancear a base, de modo que todas as quatro classes tivessem 78 imagens. O mesmo procedimento foi realizado no tipo de classificação binária (Câncer e Não-Câncer), onde foram utilizadas 380 imagens, das quais 233 foram as mesmas imagens coletadas para quatro classes e outras 147 imagens foram criadas com a técnica de vetores sintéticos.

A Tabela 14 abaixo mostra a quantidade de imagens utilizadas para ambos os tipos de classificadores.

Tabela 14 – Quantidade de imagens para quatro classes

<b>Classe</b>	<b>Quantidade de imagens</b>	<b>Novas imagens criadas pelos vetores sintéticos</b>	<b>Total de imagens</b>
Maligno	43	35	78
Benigno	78	0	78
Cisto	42	36	78
Normal	70	8	78

Fonte: VASCONCELOS (2017)

Tabela 15 – Quantidade de imagens para duas classes

<b>Classe</b>	<b>Quantidade de imagens</b>	<b>Novas imagens criadas pelos vetores sintéticos</b>	<b>Total de imagens</b>
Câncer	43	147	190
Não-Câncer	190	0	190

Fonte: VASCONCELOS (2017)

Com a amostra balanceada, um arquivo do tipo *.arff* foi criado e foi utilizado como parâmetro de entrada no *software* WEKA para classificar as imagens utilizadas. Os resultados encontrados por Vasconcelos (2017), para o classificador de quatro classes, com a mesma base de dados citada acima, utilizando os mesmos 20 atributos, estão apresentados na Tabela 16.

Tabela 16 – Resultados da classificação multiclasse através do WEKA

Classificador	Taxa de acerto	Sensibilidade	Especificidade	Acertos Maligno	Acertos Benigno	Acertos Cisto	Acertos Normal	Kappa
BayesNet	46,47%	73,08%	65,19%	73,08%	12,82%	47,73%	52,56%	0,2863
NaiveBayes	48,08%	85,90%	55,70%	85,90%	10,25%	46,15%	50,00%	0,3077
MLP	59,29%	75,64%	88,11%	75,64%	41,02%	64,10%	56,41%	0,4573
<b>SMO</b>	<b>63,46%</b>	<b>80,77%</b>	<b>86,54%</b>	<b>80,77%</b>	<b>44,87%</b>	<b>71,79%</b>	<b>56,41%</b>	<b>0,5128</b>
RandomForest	62,82%	78,21%	85,44%	78,21%	33,33%	70,51%	69,23%	0,5043
RandomTree	49,09%	66,67%	74,41%	66,67%	26,92%	53,85%	48,72%	0,3205
Ibk (KNN)	62,18%	84,62%	85,91%	84,62%	26,92%	83,33%	48,72%	0,4957

Fonte: VASCONCELOS (2017)

A matriz de confusão para este classificador SMO encontra-se na Figura 28.

Figura 28 – Matriz de Confusão da classificação da base de Vasconcelos (2017) para o classificador SMO

		CLASSIFICAÇÃO				Total de amostras
		Maligno	Benigno	Cisto	Normal	
VERDADEIRO	Maligno	63	9	3	3	78
	Benigno	10	35	20	13	78
	Cisto	3	16	56	3	78
	Normal	8	14	1	44	78
Total:					312	

Fonte: VASCONCELOS (2017)

O método de decisão do melhor classificador para esta base de dados foi baseado nas maiores taxas de acertos globais e na maior sensibilidade à Classe Maligno, além da observação da matriz de confusão juntamente com o coeficiente Kappa. Observados estes resultados, pode-se notar que o classificador, utilizado para as quatro classes, que obteve os melhores resultados foi o classificador SMO. O procedimento de validação do classificador foi realizado com validação cruzada com cinco subconjuntos, e para esse classificador foi utilizado a função *Kernel* polinomial de grau 3.

Para essa mesma condição, com os mesmos parâmetros de entrada, para os mesmos classificadores, além de outros que se encontram na biblioteca de classificação no *software* WEKA, foi realizada a combinação heterogênea de classificadores com objetivo de se melhorar os valores de acurácia no procedimento de classificação.

Dois processos de combinação heterogênea foram utilizados: *Voting* e *Stacking*. No WEKA esses procedimentos de classificação podem ser acessados da seguinte

maneira: primeiramente, importa-se o arquivo *.arff*, contendo os dados de entrada juntamente com as 20 características extraídas. Posteriormente, é acessada a janela *Classify*, escolhendo os dois tipos de combinação de classificadores através do botão *Choose > Meta > Vote* ou *Choose > Meta > Stacking*.

Após escolhidos os dois tipos de combinação heterogênea, foram escolhidos os tipos de classificadores que compuseram o sistema de combinação. Na combinação *Voting*, para a classificação contendo as quatro classes, o melhor arranjo de combinação foi obtido com os classificadores: *SMO*, *RandomForest*, *Ibk (KNN)*, *MLP*, *AttributeSelectedClassifier*, *Bagging*, *LogitBoost*, *RandomizableFilteredClassifier*, *DescisionStump*. Mais uma vez, todos os classificadores citados foram utilizados na forma padrão que o *software* apresenta, exceto o classificador *SMO* que foi modificado utilizando uma função *Kernel* polinomial de grau 3, já que este grau apresentou o melhor resultado para este classificador.

No procedimento de combinação heterogênea *Stacking*, para a classificação contendo quatro classes, o melhor arranjo de combinação para a primeira etapa do processo foi obtido com os seguintes classificadores: *RandomForest*, *Ibk (KNN)*, *AttributeSelectedClassifier*, *Bagging*, *LogitBoost*, *RandomizableFilteredClassifier*, *DescisionStump*. Todos estes foram utilizados na forma padrão conforme são apresentados no WEKA. Posteriormente, na segunda etapa de classificação, o metaclassificador utilizado foi o classificador do tipo *RandomForest*, em sua forma padrão apresentada no *software* WEKA.

Os resultados alcançados com esses dois tipos de arranjo de combinação encontram-se na Tabela 17.

Tabela 17 – Resultados da classificação multiclasse combinando classificadores através do WEKA

<b>Classificador</b>	<b>Taxa de Acerto</b>	<b>Sensibilidade</b>	<b>Especificidade</b>	<b>Acertos Maligno</b>	<b>Acertos Benigno</b>	<b>Acertos Cisto</b>	<b>Acertos Normal</b>	<b>Kappa</b>
<i>Voting</i>	71,15%	87,18%	90,06%	87,18%	47,44%	82,05%	67,95%	0,6154
<i>Stacking</i>	65,06%	80,77%	89,74%	80,77%	37,17%	70,51%	71,79%	0,5342

As matrizes de confusão para esses dois arranjos de classificação são mostradas na Figura 29.

Figura 29 – Matrizes de confusão da classificação multiclasse combinando classificadores através do WEKA

		CLASSIFICAÇÃO <i>VOTING</i>				Total de amostras
		Maligno	Benigno	Cisto	Normal	
VERDADEIRO	Maligno	68	4	2	4	78
	Benigno	11	37	23	7	78
	Cisto	2	8	64	4	78
	Normal	4	13	8	53	78
Total:					312	

		CLASSIFICAÇÃO <i>STACKING</i>				Total de amostras
		Maligno	Benigno	Cisto	Normal	
VERDADEIRO	Maligno	63	8	2	5	78
	Benigno	8	29	23	18	78
	Cisto	2	15	55	6	78
	Normal	6	14	2	56	78
Total:					312	

Com os resultados observados, pode-se notar que o procedimento de combinação de classificadores *Voting*, para este tipo de arranjo, obteve melhores resultados quando comparados ao modelo de combinação do tipo *Stacking*. A Tabela 18 mostra os resultados deste modelo de combinação *Voting* comparados com os resultados do melhor classificador individual base.

Tabela 18 – Comparação dos resultados da classificação multiclasse SMO e *Voting*

Classificador	Taxa de Acerto	Sensibilidade	Especificidade	Acertos Maligno	Acertos Benigno	Acertos Cisto	Acertos Normal	Kappa
<i>Voting</i>	71,15%	87,18%	90,06%	87,18%	47,44%	82,05%	67,95%	0,6154
SMO	63,46%	80,77%	86,54%	80,77%	44,87%	71,79%	56,41%	0,5128

Analisando esses dados, pode-se notar, facilmente, que a combinação de classificadores alcançou resultados melhores para todos os parâmetros de análise, desde a taxa de acerto, passando pela sensibilidade à Classe Maligno até o coeficiente Kappa, quando comparados com os resultados do melhor classificador individual utilizado.

Deste modo, pode-se concluir que, para este modelo de quatro classes, para classificação de imagens termográficas de mamas, a combinação de classificadores pela técnica *Voting* apresenta ser uma boa proposta de classificação, obtendo resultados percentualmente maiores quanto à taxa de acerto do classificador, com quase 10 % mais elevado do que quando a classificação é realizada com o classificador individualmente, e ao valor de sensibilidade à Classe Maligno, que alcançou uma sensibilidade a esta classe com um valor 7% maior do que o valor alcançado pelo classificador individual SMO.

O mesmo procedimento de análise foi realizado para o classificador binário, com as classes Câncer e Não-Câncer, proposto por Vasconcelos (2017). Em seu projeto a autora obteve os seguintes resultados para a base de dados, mostrados na Tabela 19.

Tabela 19 – Resultados da classificação binária através do WEKA

<b>Classificador</b>	<b>Taxa de Acerto</b>	<b>Sensibilidade</b>	<b>Especificidade</b>	<b>Kappa</b>
BayesNet	80,26%	86,84%	73,68%	0,6053
NaiveBayes	81,05%	91,58%	70,53%	0,6211
MLP	90,26%	92,63%	87,89%	0,8053
<b>SMO</b>	<b>93,42%</b>	<b>94,73%</b>	<b>92,10%</b>	<b>0,8684</b>
RandomForest	90,79%	90,52%	91,05%	0,8158
RandomTree	83,95%	84,74%	83,16%	0,6789
Ibk (KNN)	88,68%	96,31%	81,05%	0,7737

Fonte: VASCONCELOS (2017)

Baseado na escolha do classificador que apresentou a maior taxa de acerto juntamente com a maior taxa de sensibilidade à Classe Maligno, o classificador do tipo SMO foi considerado o melhor classificador, alcançando os maiores resultados. Este tipo de classificador utilizou uma função *Kernel* de grau 3. Como foi citado, foram utilizadas 380 imagens igualmente divididas entre as duas classes.

Utilizando a mesma base de dados, foi realizado o procedimento de combinação de classificadores pela técnica de combinação *Voting* e a técnica de combinação *Stacking*.

A combinação de classificadores *Voting* que obteve o melhor resultado foi aplicada utilizando os classificadores: *SMO*, *Ibk (KNN)*, *RandomTree* e *AttributeSelectedClassifier*, onde todos foram usados na sua forma padrão apresentado no *software* WEKA, exceto o classificador SMO, que como foi citado, utilizou a função *Kernel* de grau 3.

Para a aplicação da combinação *Stacking*, foram utilizados como classificadores da primeira etapa, os classificadores *SMO*, *Ibk (KNN)*, *AttributeSelectedClassifier*, todos em sua forma padrão, como apresentado no WEKA, exceto o SMO, que utilizou a função *Kernel* polinomial de grau 3. Na segunda etapa, o metaclassificador utilizado foi o classificador do tipo *RandomTree*, em sua forma padrão apresentado no *software* WEKA.

A Tabela 20 mostra os resultados alcançados com esses dois tipos de combinação de classificadores.

Tabela 20 – Resultados da classificação binária combinando classificadores através do WEKA

Classificador	Taxa de Acerto	Sensibilidade	Especificidade	Kappa
<i>Voting</i>	94,21%	95,26%	93,16%	0,8842
<i>Stacking</i>	92,89%	94,21%	91,58%	0,8579

As suas respectivas matrizes de confusão encontram-se na Figura 30.

Figura 30 – Matrizes de confusão da classificação binária combinando classificadores através do WEKA

		CLASSIFICAÇÃO		
		Câncer	Não-Câncer	Total de amostras
VERDADEIRO	Câncer	181	9	190
	Não-Câncer	13	177	190
		Total:		380

		CLASSIFICAÇÃO		
		Câncer	Não-Câncer	Total de amostras
VERDADEIRO	Câncer	179	11	190
	Não-Câncer	16	174	190
		Total:		380

Analisando os resultados, pode-se notar que, assim como no procedimento de análise anterior, onde a combinação de classificadores *Voting* apresentava melhores resultados que a combinação *Stacking*, para este tipo de arranjo, de classificação binária, o método de combinação *Voting* também obteve melhores resultados quando comparados ao modelo de combinação do tipo *Stacking*. Comparando os resultados deste modelo de combinação *Voting* com o melhor resultado de classificação dos classificadores individuais base, obtiveram-se os valores apresentados na Tabela 21.

Tabela 21 – Comparação entre resultados da classificação binária usando SMO e *Voting*

<b>Classificador</b>	<b>Taxa de Acerto</b>	<b>Sensibilidade</b>	<b>Especificidade</b>	<b>Kappa</b>
<i>Voting</i>	94,21%	95,26%	93,16%	0,8842
SMO	93,42%	94,73%	92,10%	0,8684

Analisando-se esses dados, pode-se notar que a combinação de classificadores alcançou resultados melhores quando comparados ao melhor classificador individual utilizado. Os valores da taxa de acerto do classificador, da sensibilidade à Classe Maligno e do coeficiente Kappa apresentaram melhores valores na combinação de classificadores.

Deste modo, pode-se concluir que para este modelo de classificação binária, para classificação de imagens termográficas de mamas, a combinação de classificadores pela técnica *Voting* apresenta ser uma boa proposta, obtendo resultados percentualmente maiores, quanto à taxa de acerto e ao valor da sensibilidade à Classe Maligno, comparados aos resultados dos classificadores quando são utilizados individualmente.

#### 5.4 Síntese dos resultados

No presente tópico, apresentam-se uma síntese dos resultados obtidos com as metodologias propostas, assim como comentários sobre os melhores resultados.

Foi visto que a ampliação da base de dados, com um aumento de 42% de imagens, para o classificador de Araújo (2014) em sua forma original contendo três classes de anomalias mamárias teve uma pequena influência nos resultados, diminuindo um pouco a taxa de acerto em 1%, e elevando a sensibilidade à Classe Maligno em 3%. Porém, a ampliação do número de classes do classificador de três para quatro classes, proposto na Metodologia 1, mostrou resultados bastante satisfatórios quanto à taxa de acerto e a sensibilidade à Classe Maligno.

Utilizando a mesma base de dados de 87 imagens, pôde-se comparar os resultados obtidos da Metodologia 2 com os resultados da Metodologia 1. Nesta comparação se comprovou que os resultados alcançados pela Metodologia 2 apresentaram valores inferiores aos valores alcançados pela Metodologia 1, quanto à taxa de acerto e quanto à sensibilidade à Classe Maligno. O que confirma que a Metodologia 1 apresenta ser uma boa proposta de classificação de imagens termográficas.

O procedimento de otimização junto à escolha da melhor combinação dos parâmetros de peso  $\lambda_k$  apresentou ser uma proposta bastante eficaz, quanto à decisão de escolha dessa combinação. Os resultados mostraram que, com este método, o tempo computacional caiu bastante tornando o procedimento de classificação mais rápido (5,5 vezes mais rápido) sem perder a sua eficácia quanto aos resultados de classificação.

Por fim, a técnica de combinação de classificadores mostrou que sua utilização melhora os resultados de classificação, qualificando o procedimento classificatório.

Baseado nessas informações, um breve resumo mostrando os resultados obtidos nesta dissertação além de resultados de trabalhos anteriores do mesmo grupo de pesquisa, está apresentado na Tabela 22.

Tabela 22 – Síntese dos resultados de classificação de imagens termográficas mamárias de trabalhos desenvolvidos no grupo de pesquisa do DEMEC/UFPE

	Segmentação	Classificador	Taxa de Acerto	Sensibilidade	Especificidade	Classes
Dourado Neto (2014)	Automática	SVM	79,49%	67,44%	82,20%	Câncer e Não-Câncer
Vasconcelos (2017)	Automática	SVM	93,42%	94,73%	92,10%	Câncer e Não-Câncer
<b>Metodologia 3</b>	<b>Automática</b>	<b>Combinação por Voting</b>	<b>94,21%</b>	<b>95,26%</b>	<b>93,16%</b>	<b>Câncer e Não-Câncer</b>

(a) Classificador binário

	Segmentação	Classificador	Taxa de Acerto	Sensibilidade	Especificidade	Classes
Queiroz (2016)	Automática	SVM <i>one-vs-all</i>	51,58%	66,67%	82,35%	Maligno, Benigno, Cisto e Normal
Araújo (2014)	Manual	Distância Mahalanobis	84,00%	85,70%	86,00%	Maligno, Benigno e Cisto
<b>Metodologia 1</b>	<b>Manual</b>	<b>Distância Mahalanobis</b>	<b>72,41%</b>	<b>96,30%</b>	<b>86,67%</b>	<b>Maligno, Benigno, Cisto e Normal</b>
Vasconcelos (2017)	Automática	SVM <i>one-vs-one</i>	63,46%	80,77%	86,54%	Maligno, Benigno, Cisto e Normal
<b>Metodologia 3</b>	<b>Automática</b>	<b>Combinação por Voting</b>	<b>71,15%</b>	<b>87,18%</b>	<b>90,06%</b>	<b>Maligno, Benigno, Cisto e Normal</b>

(b) Classificador multiclasse

## 6 CONCLUSÕES E TRABALHOS FUTUROS

Baseado nos resultados alcançados no presente trabalho, pode-se concluir que a termografia pode ser proposta como uma boa ferramenta no auxílio ao diagnóstico do câncer de mama. Ela mostra ser uma técnica simples, de fácil aplicação e de baixo custo que apresenta excelentes resultados quanto ao diagnóstico precoce do câncer de mama quando são usados classificadores estatísticos. Assim, coloca-se este procedimento em evidência quando comparados a outros procedimentos tradicionais de diagnóstico ao câncer de mama.

Neste trabalho foram apresentadas duas técnicas distintas de classificação do câncer de mama por meio da análise de imagens termográficas, que obtiveram resultados bastante satisfatórios no que diz respeito às taxas de acerto e às sensibilidades à Classe Maligno.

A primeira técnica de classificação consistiu na ampliação do classificador proposto por Araújo (2014). O procedimento de ampliação se deu com a inclusão de uma nova classe (Classe Normal), transformando o classificador de três para um classificador de quatro classes. Além do procedimento de ampliação de classes, foi apresentada também, uma técnica de otimização na combinação dos parâmetros de peso  $\lambda_k$  que influenciam nos resultados deste classificador. Realizadas estas mudanças, o procedimento de classificação multiclasse (Maligno, Benigno, Cisto e Normal) apresentou resultados muito bons para a classificação de anomalias mamárias, mostrando que o classificador proposto nesta metodologia apresenta alta taxa de acerto e de sensibilidade à Classe Maligno, quando comparados a outros estudos da área. A inclusão da Classe Normal causou uma diminuição na taxa de acerto do classificador, fato que já era esperado, devido à variabilidade no comportamento de distribuição dos elementos desta classe no diagrama de dispersões. Em tal diagrama, alguns pontos pertencentes a essa classe se sobrepõem às regiões pertencentes às demais classes, dificultando o processo de classificação e aumentando as chances de erro do classificador. Apesar de a inclusão da Classe Normal diminuir a taxa de acerto do classificador, há a necessidade dessa inclusão, uma vez que a ideia do projeto é utilizar a termografia como ferramenta de triagem para o diagnóstico do câncer de mama. Desta forma, todas as possíveis classes de diagnóstico devem estar presentes no classificador.

O segundo procedimento de classificação proposto nesta dissertação se deu pela combinação de classificadores, uma vez que se pôde ser comprovado que, para os parâmetros e base utilizados neste projeto, a técnica de combinação de classificadores apresentou melhores resultados quando comparados aos resultados obtidos com os classificadores individuais. Foram analisadas duas técnicas de combinação de classificadores. Pôde-se notar que a técnica de combinação *Voting* apresentou melhores resultados do que a técnica de combinação *Stacking*. Por meio do procedimento de combinação *Voting* aplicado para duas análises de classificação (uma binária e uma multiclasse) foram obtidos os melhores resultados de classificação, com altas taxas de

acerto e de sensibilidade à Classe Maligno. Todos os resultados obtidos com as duas análises de classificação apresentaram resultados melhores, se comparados aos resultados dos classificadores individuais utilizando a mesma base de dados. O fato evidencia que técnicas de combinação de classificadores, em especial a técnica de combinação *Voting*, mostra ser um procedimento que pode alcançar os melhores resultados de classificação de imagens termográficas.

Como trabalhos futuros, visando o aperfeiçoamento da técnica da termografia na área médica para o diagnóstico precoce do câncer de mama, pode-se sugerir:

- Aumentar a base de dados utilizada, visando uma base mais ampla com melhor significância do ponto de vista estatístico e balancear esta amostra, com uma quantidade uniforme de dados entre as classes;
- Realizar a comparação entre os procedimentos de segmentação manual e automático, extraíndo as mesmas características e utilizando o mesmo classificador para averiguar se as diferentes formas de segmentação influenciam a classificação estatística;
- Realizar um estudo específico analisando as influências da presença da Classe Normal nos resultados do classificador, e procurar entender e minimizar o efeito desta classe na diminuição dos resultados de classificação;
- Testar e analisar novas estratégias de combinação de classificadores estatísticos a fim de encontrar melhores resultados de classificação.

**REFERÊNCIAS**

- ACHARYA, U. R.; NG, E. Y. K.; TAN, J. H.; SREE, S. V. **Thermography based breast cancer detection using texture features and support vector machine**. Journal of Medical Systems, v. 36, p. 1503-1510, 2012.
- ACHARYA, U. R.; NG, E.; 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.
- ALPAYDIN, E. **Introduction to Machine Learning (Adaptive computation and Machine Learning)**. Cambridge: The MIT Press, 2004.
- ALTOÉ, L.; OLIVEIRA FILHO, D. **Termografia Infravermelha aplicada à inspeção de edifícios**. Acta Tecnológica, v. 7, n. 1, p. 55-59, 2012.
- AMALU, W. C. **A review of breast thermography**. International Academy of Clinical Thermography, 2002.
- ARAÚJO, M. C. **Uso de imagens termográficas para classificação de anormalidades de mama baseado em variáveis simbólicas intervalares**. Tese (Doutorado) - Universidade Federal de Pernambuco (UFPE), Recife, 2014.
- ARAÚJO, M. C.; SOUZA, R. M. C. R.; LIMA, R. C. F.; FILHO, T. M. S. **An interval prototype classifier based on a parameterized distance applied to breast thermographic images**. Med Biol Eng Comput, 2016.
- 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, p. 523-526, 2008.
- ARROYO, J. E. C. **Heurística e Metaheurística para otimização combinatória multiobjetivo**. Tese (Doutorado), Universidade Estadual de Campinas, 2002.
- BALBINOT, L. F. **Diagnóstico de Neuropatia no diabetes Mellitus Tipo 2 e no pré-diabetes**. Tese (Doutorado) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2012.
- BANKMAN, I. N. **Segmentation**. In Handbook of Medical Image Processing and Analysis. Elsevier Inc, 2009.
- BASHIRI, M.; SALMASNIA, A. **Decision Making for Interactive Optimization of correlated desirability functions**. Industrial Engineering and Engineering Management, IEEE International Conference on Hong Kong, p. 2075-2079, 2009.

BERNARDINI, F. C. **Combinação de classificadores simbólicos para melhorar o poder preditivo e descritivo de *Ensembles***. Dissertação (Mestrado), Universidade de São Paulo, São Carlos, 2002.

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

BRANDÃO, M. A. L. **Estudo de alguns métodos determinísticos de otimização irrestrita**. Dissertação (Mestrado) – Universidade Federal de Uberlândia, Brasil, 2010.

BRIOSCHI, M. L. **A história da termografia**. Instituto de Física de São Carlos, Universidade de São Paulo, v. 91, n. 92, p. 7-17, 2008.

BUSACCA, G. P.; MARSEGUERRA, M.; ZIO, E. **Multi-objective optimization by genetic algorithms: application to safety systems**. Reliability Engineering & System Safety, v. 72, n. 1, p. 59-74, 2001.

CAMARGO, L. W. F. **Ajuste de parâmetros para desalinhamento e empenamento aplicado à modelagem de rotores**. Dissertação (Mestrado), Universidade Estadual de Campinas, São Paulo, 2010.

CARNEIRO, P. C. **Classificação mamográfica por densidade mamária utilizando atributos de intensidade e textura**. Dissertação (Mestrado), Universidade Federal de Uberlândia, 2015.

CASTRO, R. E. **Otimização de estruturas com multiobjetivos via algoritmos genéticos**. Tese (Doutorado), Universidade Federal do Rio de Janeiro, 2001.

CÔRTE, A. C. R.; HERNANDEZ, A. J. **Termografia Médica Infravermelha aplicada à medicina do esporte**. Rev Bras Med Esporte, v. 22, n. 4, p. 315-319, 2016.

CORTIZO, E. C.; BARBOSA, M. P.; SOUZA, L. A. C. **Estado da arte da termografia**. Fórum Patrimônio: Ambiente Construído e Patrimônio Sustentável, Belo Horizonte, v. 2, n. 2, p. 158-193, 2008.

DANAEI, G.; HOORN, V. S.; LOPEZ, A. D.; MURRAY, C. J.; EZZATI, M. **Causes of cancer in the world: comparative risk assessment of nine behavioural and environmental risk factors**. The Lancet, v. 366, n. 9499, p. 1784-1793, 2005.

DEB, K. **Multi-objective Optimization using Evolutionary Algorithms**. New York: John Wiley & Sons, 2001.

DIAKIDES, N. A.; DIAKIDES, M.; LUPO, J. C.; PAUL, J. L.; BALCERAK, R. **Advances in Medical Infrared Imaging**. Medical Devices and Systems, The Biomedical Engineering Handbook, Edited by Joseph D. Bronzino, 3<sup>rd</sup> Edition, CRC Press, USA, 2006.

DIETTERICH, T. G. **Ensemble methods in machine learning**. In the 1<sup>st</sup> Int. Work. On Multiple Classifiers Systems, p. 1-15, 2000.

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**. Dissertação (Mestrado) – Universidade Federal de Pernambuco, Recife, 2014.

EDGAR, T. F.; HIMMELBLAU, D. M.; LASDON, L. S. **Optimization of Chemical Process**. 2<sup>nd</sup> ed., New York: McGraw-Hill Chemical Engineering Series, 2001.

FLIR SYSTEMS. ThermaCAMTMS45. Manual do operador. [S.1], 2004.

GAMAGAMI, P.; SILVERSTEIN, M. J.; WAISMAN, J. R. **Infrared Imaging in Breast Cancer**. Proceedings of the 19<sup>th</sup> International Conference of the IEEE/EMBS, Chicago, IL, USA, October 30-November 02, p. 677-680, 1997.

GAUTHERIE, M.; GROS, C. M. **Breast Thermography and Cancer Risk Prediction**. Cancer, v. 45, n. 1, p. 51-56, 1980.

GOMES, F. M. **Diferentes métodos de aglutinação para melhoria de processos com múltiplas respostas**. Tese (Doutorado), Universidade Estadual Paulista, Guaratinguetá, 2015.

GOMES, J. H. F. **Método dos polinômios canônicos de misturas para otimização multi-objetivo**. Tese (Doutorado), Universidade Federal de Itajubá, Minas Gerais, 2013.

GONZALEZ, R. C.; WOODS, R. E.; EDDINS, E. L. **Digital Image Processing Using Matlab**. 3<sup>rd</sup> ed., New Jersey: Pearson Prentice Hall, 2008.

INCA. **Instituto Nacional de Câncer**. Estimativa 2017: Incidência do Câncer no Brasil. Rio de Janeiro, Brasil: Ministério da Saúde, 2016.

INCROPERA, F. P.; DEWITT, D. P.; BERGMAN, T. L.; LAVINE, A. S. **Fundamentos de transferência de calor e massa**. 6. Ed. Rio de Janeiro: LTC, 2008.

HALLIDAY, D.; RESNICK, R.; WALKER, J. **Fundamentos da Física**. 8. Ed., Wiley, 2008.

HARZBECKER, K.; HOPNER, S.; MAHRLEIN, W.; KRAUSE, M.; MULLER H. R. **Thermographic thorax diagnostics**. Z Gesamte Inn Med, v. 33, n. 3, p. 78-80, 1978.

HEAD, J. F.; WANG, F.; ELLIOTT, R. L. **Breast Thermography is a noninvasive prognostic procedure that predicts tumor growth rate in breast cancer patients**. Annals of the New York Academy of Sciences, v. 698, n. 1, p.153-158, 1993.

HERENDIA-LANGNER, A.; MONTEGOMERY, D. C.; CARLYLE, W. M. **Solving a multistage partial inspection problem using genetic algorithms**. International Journal of Production Research, v. 40, p. 1923-1940, 2002.

JAIN, A. K.; DUIN, R. P. W.; MAO, J. **Statistical Pattern Recognition: a review**. IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 22, n. 1, p. 4-37, 2000.

JARRETA NETO, C. **Termografia aplicada à detecção e dimensionamento de descontinuidades em tubulações de compósito**. Dissertação (Mestrado), Universidade Federal do Rio Grande do Sul, Porto Alegre, 2009.

JURBERG, C.; GOUVEIA, M. E.; BELISÁRIO C. **Na mira do câncer: o papel da mídia brasileira**. Revista Brasileira de Cancerologia, v. 52, n. 2, p.139-146, 2006.

KAPOOR, P.; PRASAD, S. V. A. V. **Image Processing for early diagnosis of breast cancer using infrared images**. In 2<sup>nd</sup> International Conference on Computer and Automation Engineering, v. 3, n. 1, p. 564-566, 2010.

KEYSERLINGK, J. R.; AHLGREN, P. D.; YU, E.; BELLIVEAU, N. **Infrared Imaging of the Breast: Initial Reappraisal Using High-Resolution Digital Technology in 100 Successive Cases of Stage I and II Breast Cancer**. The Breast Journal, v. 4, n. 4, p. 245-251, 1998.

KOAY, J.; HERRY, C.; FRIZE, M. **Analysis of Breast Thermography with an Artificial Neural Network**. Proceedings of the 26<sup>th</sup> Annual International Conference of the IEEE (EMBS), San Francisco, CA, USA, p.1159-1162, 2004.

KRAWCZYK, B.; SCHAEFER, G. **A hybrid classifier committee for analyzing asymmetry features in breast thermograms**. Applied Soft Computing, v. 20, p. 112-118, 2014.

KUNCHEVA, L. I. **Combining Pattern Classifiers: methods and algorithms**. Wiley-Interscience, 2004.

LAHIRI, B. B.; BAGAVATHIAPPAN, S.; JAYAKUMAR, T.; PHILIP, J. **Medical applications of infrared thermography: A review**. Infrared Physics & Technology, v. 55, p. 221-235, 2012.

LAWSON, R. **Implications of surface temperatures in the diagnosis of breast cancer**. Can Med Assoc J, v. 75, n. 4, p. 309-310, 1956.

LINDEN, G. S. **Combinação de classificadores na categorização de texto**. Dissertação (Mestrado), Pontifícia Universidade Católica do Rio Grande do Sul, Porto Alegre, 2008.

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.

LUCENA, D. V. **Algoritmos evolutivos Multiobjetivo para seleção de variáveis em problemas de calibração multivariada**. Dissertação (Mestrado), Universidade Federal de Goiás, Goiânia, 2013.

MALZYNER, A.; CAPONERO, R. **Câncer e Prevenção**. 1 ed. São Paulo, MG Editores, 2013.

MARÇAL, M. A.; ELIAS, A. P. V.; SILVA, F. F. D. **Uso da termografia infravermelha na identificação de dor em trabalhadores encaminhados para reabilitação**. Blucher Engineering Proceedings, v.3, n. 3, p. 959-969, 2016.

MARQUES, R. S.; RESMINI, R.; CONCI, A.; FONTES, C. A. P.; LIMA, R. C. F. **Método para segmentação manual de imagens térmicas para geração de GroundTruth**, 2012.

MARUYAMA, S. A. T.; COSTA, A. L. C.; SANTO, E. A. R. E.; BELLATO, R.; PEREIRA, W. R. **O corpo e a cultura como lócus do câncer**. Cogitare Enfermagem (UFPR), v. 11, n. 2, p. 171-175, 2006.

MATHWORKS, T. **Matlab Documentation**. Disponível em, 2016.

MEIRA, L. F.; KRUEGER, E.; NEVES, E. B.; NOHAMA, P.; SOUZA, M. A. **Termografia na Área Biomédica**. Pan American Journal of Medical Thermology, v. 1, n. 1, p. 31-41, 2014.

MENESES, P. R.; SANO, E. E. **Introdução ao processamento de imagens de sensoriamento remoto**, Brasília UNB/CNPq, 2012.

MOGHADDAMA; ATEFEH; YALAOUIA; FAROUK; AMODEO; LIONEL. **Efficient meta-heuristics based on various dominance criteria for a single-machine bi-criteria scheduling problem with rejection**. Journal of Manufacturing Systems, v. 34, p. 12-22, 2015.

MOGHBEL, M.; MASHOHOR, S. **A review of computer assisted detection/diagnosis (CAD) in breast thermography for breast cancer detection**. Artif Intell Rev, v. 39, p. 305-313, 2011.

MOTTA, L. S. **Obtenção automática da região de interesse em termogramas frontais da mama para o auxílio à detecção precoce de doenças**. Dissertação (Mestrado), Universidade Federal Fluminense, Niterói, 2010.

NAHM, F. S.; KOO, M. S.; KIM, Y. H.; SUH, J. H.; SHIN, H. Y.; CHOI, Y. M. **Infrared Thermography in the Assessment of Temporomandibular Joint Disorder**. Korean J Pain, v. 20, n. 2, p 163-168, 2007.

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

NG, E. Y. K.; CHONG, C.; KAW, G. J. L. **Classification of human facial and aural temperature using neural networks and IR fever scanner: A responsible second look.** Journal of Mechanics in Medicine and Biology, v. 5, n. 1, p. 165-190, 2005.

NG, E. Y. K.; KEE, E. C. **Integrative computer-aided diagnostic with breast thermogram.** Journal of mechanics in medicine and biology, v. 7, n. 1, p. 1-10, 2007.

NG, E. Y. K.; KEE, E.; ACHARYA, R. U. **Advanced technique in breast thermography analysis.** Proceedings of the IEEE Engineering in Medicine and Biology 27<sup>th</sup> Annual Conference, Shangay, China, 2005.

NG, E. Y. K.; SUDHARSAN, N. M. **Numerical computation as a tool to aid thermographic interpretation.** Journal of Medical Engineering & Technology, v. 25, n. 2, p. 53-60, 2001.

NIEHOF, S. P.; HUYGEN, F. J.; STRONKS, D. L.; KLEIN, J.; ZIJLSTRA, F. J. **Reliability of observer assessment of thermographic images in complex regional pain syndrome type 1.** Acta Orthop Belg, v. 73, n. 1, p. 31-37, 2007.

NILSON, C. P. **Aquisição, processamento de sinais mioelétricos e máquina de vetores de suporte para caracterização de movimentos do segmento mão-braço.** Dissertação (Mestrado), Universidade Federal do Rio Grande do Sul, Porto Alegre, 2014.

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

ORTIZ, F.; SIMPSON, J. R.; PIGNATIELLO, J. J.; HEREDIA-LANGNER, A. A **Genetic Algorithm approach to Multiple-Response Optimization.** Journal of Quality Technology, v. 36, n. 4, p. 432-450, 2004.

OSYCZKA, A. **Multicriteria optimization for engineering design.** Designe optimization, v. 1, p. 193-227, 1985.

PAIVA, E. J. **Erro Quadrático Médio Multivariado na otimização do torneamento do aço ABNT 52100 endurecido.** Tese (Doutorado), Universidade Federal de Itajubá, Minas Gerais, 2012.

PAL, S.; GAURI, S. K. **Assessing effectiveness of the various performance metrics for multi-response optimization using multiple regression.** Computers & Industrial Engineering, v. 59, p. 976-985, 2010.

PAULA, T. I. **Avaliação da influência de parâmetros do algoritmo genético na otimização de um problema multiobjetivo utilizando-se Arranjo de Misturas.** Dissertação (Mestrado), Universidade Federal de Itajubá, 2015.

PEDRINI, H.; SCHWARTZ, W. R. **Análise de imagens digitais: princípios, algoritmos e aplicações.** Connecticut, USA: Thomson Learning, 2008.

PETTRES, R.; LACERDA, L. A. **Reconhecimento de padrões de defeitos em concreto a partir de imagens térmicas estacionárias e redes neurais artificiais.** Ágora: Revista de Divulgação Científica, v. 17, n. 2, p. 1-12, 2012.

PHOLDEE, N.; BUREERAT, S. **Comparative performance of metaheuristic algorithms for mass minimization of trusses with dynamic constraints.** Advances in Engineering Software, v. 75, p. 1-13, 2014.

PONTI JUNIOR, M. P. **Combinação de múltiplo classificadores para identificação de materiais em imagens ruidosas.** Dissertação (Mestrado), Universidade Federal de São Carlos, 2004.

PONTI JUNIOR, M. P. **Combining classifiers: from the creation of ensembles to decision fusion.** Conference on Graphics, Patterns and Images Tutorials, p. 1-10, 2011.

PRADO, B. B. F. **Influência dos hábitos de vida no desenvolvimento do câncer.** Ciência e Cultura, v. 66, n. 1, p. 21-24, 2014.

PRESÍDIO, L. R.; WANDERLEY, F. G. C.; MEDRADO, A. R. A. P. **O uso da termografia infravermelha na odontologia e suas especialidades: Uma revisão sistemática.** Revista Bahiana de Odontologia, v. 7, n. 2, 2016.

QI, H.; DIAKIDES, N. A. **Thermal Infrared Imaging in Early Breast Cancer Detection – A Survey of Recent research.** Proceedings of the 25<sup>th</sup> Annual International Conference of the IEEE (EMBS), Cancun, Mexico, September 17-21, p.1109-1112, 2003.

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

QUEIROZ, K. F. F. C. **Desenvolvimento e implementação de uma ferramenta computacional de uso médico para análise de imagens termográficas.** Dissertação (Mestrado), Universidade Federal de Pernambuco, Recife, 2016.

RAMPAZZO, P. C. B. **Planejamento Hidrelétrico: Otimização multiobjectivo e abordagens evolutivas.** Tese (Doutorado), Universidade Estadual de Campinas, 2012.

RAO, S. S. **Engineering optimization: theory and practice.** 4<sup>th</sup> ed. New Jersey: John Wiley & Sons, 2009.

RAO, S. S.; FREIHEIT, T. I. **A modified Game Theory Approach to Multiobjective Optimization.** Journal of Mechanical Design, v.113, p. 286, 1991.

RESMINI, R.; CONCI, A.; BORCHARTT, T. B.; LIMA, R. C. F.; MONTENEGRO, A. A.; PANTALÃO, C. A. **Diagnóstico precoce de doenças mamárias usando imagens térmicas e aprendizado de máquina,** Revista Eletrônica do Alto Vale de Itajaí, n. 1, p. 55-67, UFF e UFPE, 2012.

REZENDE, A. B. **Ajuste de Parâmetros em Sistemas Rotativos Através de Otimização Multiobjetivo**. Dissertação (Mestrado), Universidade Estadual de Campinas, 2016.

RING, E. F. J. **The historical development of thermal imaging in medicine**. *Rheumatology*, v.43, p. 800-802, 2004.

RING, E. F. J. **The historical development of temperature measurement in medicine**. *Infrared Physics & Technology, Workshop on Advanced Infrared Technology and Applications*, v. 49, n. 3, p. 297-31, 2007.

RING, F.; JUNG, A.; ZUBER, J. **New Opportunities for Infrared Thermography in Medicine**. *Acta Bio-Optica et Informatica Medica*, v. 15, p. 28-30, 2009.

ROCHA, A. D. D. **Detecção e classificação de lesões em imagens de mamografia usando classificadores SVM, wavelets morfológicas e seleções de atributos**. Dissertação (Mestrado), Universidade Federal de Pernambuco, Recife, 2016.

SANCHES, I. J. **Sobreposição de imagens de termografia e ressonância magnética: Uma nova modalidade de imagem médica tridimensional**. Tese (Doutorado) – Universidade Tecnológica Federal do Paraná, Curitiba, 2009.

SANTANA, L. E. A.; OLIVEIRA, D. F.; CANUTO, A. M.; SOUTO, M. C. P. **A comparative analysis of feature selection methods for ensembles with different combination methods**. *International Joint Conference on Neural Networks*, p. 643-648, 2007.

SANTOS, A. B. **Combinação de múltiplas abordagens de classificação para interpretação de imagens hiperespectrais de sensoriamento remoto**. Dissertação (Mestrado), Universidade Federal de Minas Gerais, Belo Horizonte, 2013.

SBFÍSICA. **Sociedade Brasileira de Física**. 2017.

SCHAEFER, G.; ZAVISEK, M.; NAKASHIMA, T. **Thermography based breast cancer analysis using statistical features and fuzzy classification**. *Pattern Recognition*, v. 47, p. 1133-1137, 2009.

SELFIDGE, O. G. **Pandemonium: a paradigm for learning in mechanization of thought processes**. *Symposium Held at the National Physical Laboratory*, p. 513-526, 1958.

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

SILVA FILHO, L. V. **Uma arquitetura para combinação de classificadores otimizada por métodos de poda com aplicação em *credit score***. Dissertação (Mestrado), Universidade Federal de Pernambuco, Recife, 2014.

SOUZA, R. M. C. R.; CARVALHO, F. A. T. TENÓRIO, C. P. **Dynamic cluster methods for interval data based on mahalanobis distances**. In: Proceedings of the meeting of the International Federation of Classifications Societies (IFCS). Classification Clustering and Data Mining Applications, p. 351-360, 2004.

SPITALIER, H.; GIRAUD D. **Does infrared thermography truly have a role in present-day breast cancer management?**. Biomedical Thermology, p. 269-278, 1982.

SUDENG, S.; WATTANAPONGSAKORN N. **Post Pareto-optimal pruning algorithm for multiple objective optimization using specific extended angle dominance**. Engineering Applications of Artificial Intelligence, v. 38, p. 221-236, 2015.

TANG, X.; DING H.; YUAN, Y.; WANG, Q. **Morphological measurements of localized temperature increase amplitudes in breast infrared thermograms and its clinical application**. Biomedical Signal Processing and Control, v. 3, p. 312-318, 2008.

TUMER, K.; GHOSH, J. **Error correlation and error reduction in ensemble classifiers**. Connection Science, v. 8, p. 385-404, 1996.

VASCONCELOS, J. H. **Investigação sobre métodos de classificação para uso em termografia de mama**. Dissertação (Mestrado) – Universidade Federal de Pernambuco, Recife, 2017.

VERATTI, A. B. **Termografia: princípios, aplicações e qualidade**. SP: ICON Tecnologia, 1992.

WOLPERT, D. H. **The lack of a priori distinctions between learning algorithms**. Neural Computation, v. 8, n. 7, p. 1341-1390, 1996.

WOZNIAK, M.; GRAÑA, M.; CORCHADO, E. **A survey of multiple classifier systems as hybrid systems**. Information Fusion, v. 16, p. 3-17, 2014.

ZINI, E. O. C. **Algoritmo Genético especializado na resolução de problemas com variáveis contínuas e altamente restritos**. Dissertação (Mestrado), Universidade Estadual Paulista, Ilha Solteira, 2009.