

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Caroline Barcelos Gonçalves

**Deteccção de câncer de mama utilizando  
imagens termográficas**

**Uberlândia, Brasil**

**2017**

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Caroline Barcelos Gonçalves

**Detecção de câncer de mama utilizando imagens  
termográficas**

Trabalho de conclusão de curso apresentado  
à Faculdade de Computação da Universidade  
Federal de Uberlândia, Minas Gerais, como  
requisito exigido parcial à obtenção do grau  
de Bacharel em Ciência da Computação.

Orientador: Henrique Coelho Fernandes

Universidade Federal de Uberlândia – UFU

Faculdade de Ciência da Computação

Bacharelado em Ciência da Computação

Uberlândia, Brasil

2017

Caroline Barcelos Gonçalves

## **Detecção de câncer de mama utilizando imagens termográficas**

Trabalho de conclusão de curso apresentado à Faculdade de Computação da Universidade Federal de Uberlândia, Minas Gerais, como requisito exigido parcial à obtenção do grau de Bacharel em Ciência da Computação.

Trabalho aprovado. Uberlândia, Brasil, 15 de dezembro de 2017:

---

**Henrique Coelho Fernandes**  
Orientador

---

**Maria Adriana Vidigal de Lima**

---

**Marcelo Zanchetta do Nascimento**

Uberlândia, Brasil  
2017

*Dedico aos meus pais, Angelina e João, a minha irmã Karinne.*

# Agradecimentos

Agradeço primeiramente a Deus, meu Criador, Senhor, Salvador e Consolador. Aquele que me deu a vida, me ama, me sustenta, é o meu refúgio, esperança e fortaleza e não me desampara. Obrigada Senhor por todas as graças derramadas sobre mim. Agradeço a Virgem Maria, mãe de Deus e minha, por sua constante presença, sua intercessão, seu amparo e socorro em toda a minha vida.

Agradeço ao meu orientador, Henrique Fernandes, por todos os ensinamentos, por cada palavra de encorajamento e motivação, por confiar em mim, pela paciência e atenção para que esse trabalho fosse realizado da melhor maneira possível. Agradeço ainda ao professor Gilmar Guimarães por disponibilizar a base de dados utilizada neste trabalho.

Agradeço aos meus pais, Angelina e João, e a minha irmã Karinne por todo amor incondicional. Por serem minha força, meu amparo, minha segurança. Obrigada por todo exemplo, toda sabedoria, por acreditarem em mim, por me motivarem, por me acolherem, por toda paciência e por toda ajuda. Obrigada por cada sacrifício que fizeram por mim.

Aos meus avós, tios, tias e primas obrigada por torcerem por mim, por alegrarem os meus dias, pelo exemplo e cuidado.

Aos meus amigos, o meu muito obrigada por fazerem parte dessa jornada comigo. Obrigada por fazerem esses últimos anos tão especiais. Obrigada por cada sorriso e cada lágrima compartilhados. Obrigada por toda paciência e carinho. Aos meus amigos da RCC, obrigada por estarem ao meu lado, obrigada por serem meu amparo, obrigada por cada oração e por cada intercessão.

A special thanks to my dear friend Dr. Layan Nahlawi, who taught me a lot personally and professionally. Thank you for being such an inspiration for me, as a woman, as a researcher, as a professional. Thank you for each experiment and all the coding we did together, for helping me during my time in Kingston, for each conversation and for all the advices that I will carry with me for my entire life. Working with you was really important for the development of this thesis.

# Resumo

O câncer de mama é a doença que mais mata mulheres em todo o mundo. O diagnóstico precoce é fundamental para maiores chances de cura e recuperação das pacientes. As imagens termográficas devido a potencialidade de detectar a doença precocemente em mulheres jovens, ausência de radiação e ao baixo custo tem se mostrado uma técnica promissora. Esta monografia apresenta uma metodologia que classifica as pacientes como normais, com alterações benignas e com câncer (alterações malignas) a partir de imagens termográficas da mama. A base de dados utilizada é composta por imagens de 70 pacientes. Algumas das características consideradas foram medidas estatísticas e dimensão fractal. A classificação é feita através de Redes Neurais Artificiais (RNA) e Máquina de Vetores de Suporte (SVM). O melhor resultado obtido foi 80.95% de acurácia, 83.33% de especificidade para pacientes normais, 85.71% de especificidade para pacientes com alterações benignas e 75% de sensibilidade. Este resultado foi obtido considerando as características: média, desvio padrão, mediana, temperatura mínima, temperatura máxima, amplitude térmica, assimetria, curtose, entropia, contraste, correlação, momento 2, momento 3 e momento 4 para descrever as imagens e utilizando o classificador SVM. Os resultados obtidos se mostram promissores e confirmaram a premissa de que as imagens termográficas podem auxiliar na detecção do câncer de mama.

**Palavras-chave:** termografia, câncer de mama, extração de características, redes neurais artificiais, máquina de vetores de suporte.

# Lista de ilustrações

|                                                                                                                                  |    |
|----------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 1 – Exemplo câmera infravermelha Flir T460 - extraído de (SYSTEMS, 2014)                                                  | 16 |
| Figura 2 – Espectro eletromagnético - extraído de (IBARRA-CASTANEDO, 2005)                                                       | 17 |
| Figura 3 – Imagem antes e depois da aplicação do Otsu - extraída de (OTSU, 1979)                                                 | 19 |
| Figura 4 – Exemplo da aplicação do filtro de mediana com vizinhança 3x3 - extraído de (BACKES, 2015)                             | 20 |
| Figura 5 – Exemplo da aplicação do filtro gaussiano - extraído de (JESUS; JR, 2015)                                              | 21 |
| Figura 6 – Ilustração dados não lineares, espaço de entrada e espaço das características. - extraído de (LORENA; CARVALHO, 2007) | 23 |
| Figura 7 – Ilustração de um perceptron - extraída de (CASTRO, 2012)                                                              | 24 |
| Figura 8 – Ilustração de uma rede neural com duas camadas ocultas - extraída de (CASTRO, 2012)                                   | 25 |
| Figura 9 – Expressão 1 - Cálculo da Acurácia extraído de (BORCHARTT, 2013)                                                       | 26 |
| Figura 10 – Expressão 2 - Cálculo da Sensibilidade extraído de (BORCHARTT, 2013)                                                 | 26 |
| Figura 11 – Expressão 3 - Cálculo da Especificidade extraído de (BORCHARTT, 2013)                                                | 26 |
| Figura 12 – Etapas da metodologia                                                                                                | 31 |
| Figura 13 – Exemplo de imagem de paciente normal                                                                                 | 32 |
| Figura 14 – Exemplo de imagem de paciente com tumor benigno                                                                      | 33 |
| Figura 15 – Exemplo de imagem de paciente com tumor maligno                                                                      | 33 |
| Figura 16 – Ilustração das etapas do pré-processamento para paciente 57                                                          | 35 |
| Figura 17 – Gráfico comparativo entre os dois classificadores                                                                    | 51 |

# Lista de tabelas

|                                                          |    |
|----------------------------------------------------------|----|
| Tabela 1 – Características extraídas das mamas . . . . . | 36 |
| Tabela 2 – Resultados significativos da RN. . . . .      | 48 |
| Tabela 3 – Resultados significativos do SVM. . . . .     | 50 |

# Lista de abreviaturas e siglas

|     |                               |
|-----|-------------------------------|
| SVM | Máquina de Vetores de Suporte |
| RNA | Redes Neurais Artificiais     |
| Acc | Acurácia                      |
| ROI | Região de Interesse           |
| TIR | Termografia Infravermelha     |
| VP  | Verdadeiro Positivo           |
| VN  | Verdadeiro Negativo           |
| FP  | Falso Positivo                |
| FN  | Falso Negativo                |

# Sumário

|            |                                                    |           |
|------------|----------------------------------------------------|-----------|
| <b>1</b>   | <b>INTRODUÇÃO</b>                                  | <b>11</b> |
| <b>1.1</b> | <b>Contexto e Motivação</b>                        | <b>11</b> |
| <b>1.2</b> | <b>Objetivos e Método de pesquisa</b>              | <b>13</b> |
| <b>1.3</b> | <b>Resultados alcançados</b>                       | <b>13</b> |
| <b>1.4</b> | <b>Estrutura da monografia</b>                     | <b>14</b> |
| <b>2</b>   | <b>REFERENCIAL TEÓRICO</b>                         | <b>15</b> |
| <b>2.1</b> | <b>Câncer de mama</b>                              | <b>15</b> |
| <b>2.2</b> | <b>Termografia infravermelha</b>                   | <b>16</b> |
| <b>2.3</b> | <b>Processamento das imagens</b>                   | <b>17</b> |
| 2.3.1      | Segmentação                                        | 17        |
| 2.3.1.1    | Otsu                                               | 18        |
| 2.3.2      | Filtros                                            | 19        |
| 2.3.2.1    | Filtro de mediana                                  | 19        |
| 2.3.2.2    | Filtro Gaussiano                                   | 20        |
| <b>2.4</b> | <b>Descritores de Textura</b>                      | <b>20</b> |
| <b>2.5</b> | <b>Classificadores</b>                             | <b>21</b> |
| 2.5.1      | Máquina de Vetores de Suporte                      | 22        |
| 2.5.2      | Redes Neurais Artificiais                          | 23        |
| 2.5.3      | Métodos de avaliação dos classificadores           | 25        |
| <b>3</b>   | <b>REVISÃO BIBLIOGRÁFICA</b>                       | <b>27</b> |
| <b>3.1</b> | <b>Trabalhos correlatos</b>                        | <b>27</b> |
| <b>4</b>   | <b>MATERIAIS E MÉTODOS</b>                         | <b>31</b> |
| <b>4.1</b> | <b>Base de dados</b>                               | <b>31</b> |
| <b>4.2</b> | <b>Pré-processamento e segmentação das imagens</b> | <b>33</b> |
| <b>4.3</b> | <b>Extração das características</b>                | <b>35</b> |
| 4.3.1      | Medidas estatísticas                               | 36        |
| 4.3.1.1    | Média                                              | 36        |
| 4.3.1.2    | Desvio Padrão                                      | 36        |
| 4.3.1.3    | Mediana                                            | 37        |
| 4.3.1.4    | Temperatura Mínima                                 | 37        |
| 4.3.1.5    | Temperatura Máxima                                 | 37        |
| 4.3.1.6    | Amplitude Térmica                                  | 37        |
| 4.3.1.7    | Assimetria                                         | 38        |

|            |                                                                                              |           |
|------------|----------------------------------------------------------------------------------------------|-----------|
| 4.3.1.8    | Curtose . . . . .                                                                            | 38        |
| 4.3.1.9    | Entropia . . . . .                                                                           | 38        |
| 4.3.2      | Medidas estatísticas obtidas a partir da matriz de co-ocorrência de nível de cinza . . . . . | 39        |
| 4.3.2.1    | Contraste . . . . .                                                                          | 39        |
| 4.3.2.2    | Correlação . . . . .                                                                         | 39        |
| 4.3.2.3    | Homogeneidade . . . . .                                                                      | 39        |
| 4.3.2.4    | Energia . . . . .                                                                            | 40        |
| 4.3.3      | Momento estatístico . . . . .                                                                | 40        |
| 4.3.4      | Dimensão Fractal . . . . .                                                                   | 40        |
| 4.3.4.1    | Dimensão Box Counting . . . . .                                                              | 40        |
| <b>4.4</b> | <b>Classificação</b> . . . . .                                                               | <b>41</b> |
| <b>4.5</b> | <b>Avaliação</b> . . . . .                                                                   | <b>41</b> |
| <b>5</b>   | <b>EXPERIMENTOS E RESULTADOS</b> . . . . .                                                   | <b>43</b> |
| <b>5.1</b> | <b>Experimentos</b> . . . . .                                                                | <b>43</b> |
| 5.1.1      | Dados de entrada . . . . .                                                                   | 43        |
| 5.1.2      | Combinações de características consideradas . . . . .                                        | 43        |
| 5.1.3      | Parâmetros específicos da RNA . . . . .                                                      | 44        |
| 5.1.3.1    | Número de neurônios . . . . .                                                                | 44        |
| 5.1.4      | Parâmetros específicos do SVM . . . . .                                                      | 44        |
| 5.1.4.1    | Função Kernel . . . . .                                                                      | 44        |
| 5.1.4.2    | Abordagem classificação multiclasse . . . . .                                                | 44        |
| 5.1.5      | Validações . . . . .                                                                         | 44        |
| <b>5.2</b> | <b>Resultados</b> . . . . .                                                                  | <b>45</b> |
| 5.2.1      | Testes com RNA como classificador . . . . .                                                  | 45        |
| 5.2.2      | Testes com SVM como classificador . . . . .                                                  | 47        |
| 5.2.3      | Comparando os classificadores . . . . .                                                      | 51        |
| 5.2.4      | Discussão dos resultados . . . . .                                                           | 52        |
| <b>6</b>   | <b>CONCLUSÃO</b> . . . . .                                                                   | <b>53</b> |
| <b>6.1</b> | <b>Trabalhos futuros</b> . . . . .                                                           | <b>53</b> |
|            | <b>REFERÊNCIAS</b> . . . . .                                                                 | <b>55</b> |

# 1 Introdução

## 1.1 Contexto e Motivação

O câncer de mama é o segundo tipo de câncer mais comum no mundo e o mais comum entre mulheres. Estima-se que em 2012, esse tipo de câncer incidia sobre 1.7 milhão de mulheres, sendo que, 25% desses casos no ano em questão correspondiam a novos casos (INCA, 2016), (FERLAY I. SOERJOMATARAM, 2012). Estudos indicam que o número de casos do câncer de mama variam ligeiramente entre países menos e mais desenvolvidos (FERLAY I. SOERJOMATARAM, 2012). Nos países desenvolvidos, as melhores condições para o tratamento da doença levam a menores taxas de mortalidade que nos países menos desenvolvidos, sendo que nos países menos desenvolvidos o câncer de mama é o tipo de câncer que causa maior número de morte em mulheres, ocupando a segunda posição nos países mais desenvolvidos (FERLAY I. SOERJOMATARAM, 2012).

No Brasil, estimativas para os anos de 2016 e 2017 indicam que este tipo de câncer corresponderá a quase 30% do número de novos casos da doença (INCA, 2016). Em mulheres jovens o número de casos de câncer de mama tem aumentado (ARAÚJO, 2009), (BORCHARTT, 2013). A detecção precoce da doença é fundamental já que quanto mais cedo a doença é descoberta melhores são os tratamentos e as chances de cura da paciente, o que levaria a uma diminuição na taxa de mortalidade em decorrência desse tipo de câncer (ARAÚJO, 2009), (BORCHARTT, 2013). De acordo com Lessa e Marengoni (2016), a chance de cura do câncer de mama cai drasticamente se a doença não for descoberta nos estágios iniciais.

A mamografia é o exame mais comum para detecção do câncer de mama (BORCHARTT, 2013). No Brasil, o Sistema Único de Saúde (SUS) oferece o exame a todas as mulheres acima de 40 anos. A sensibilidade (proporção de casos de câncer corretamente classificados como cancerígenos) proporcionada pelo exame depende de alguns fatores relacionados a características como tamanho, localização do tumor e densidade da mama (LELES et al., 2015). Este exame, isto é, a mamografia, apresenta deficiências na detecção da doença no caso de mamas densas, que são mamas formadas principalmente por tecido glandular, que é o caso da maioria das pacientes jovens (BORCHARTT, 2013). Outro problema é a exposição aos raios X; mamas com tecido glandular denso absorvem mais radiação e conseqüentemente são mais sensíveis aos efeitos prejudiciais desta, podendo inclusive aumentar as chances da mulher desenvolver a doença (ARAÚJO, 2009), (LELES et al., 2015), (BORCHARTT et al., 2013).

O autoexame e o exame clínico são normalmente os primeiros procedimentos a

serem realizados em busca de alterações suspeitas. Ambos os procedimentos são manuais. No autoexame, a paciente apalpa a mama procurando as alterações. Já no exame clínico, um especialista apalpa a mama também em busca de alterações. Diversos outros exames baseados em imagem também podem ser utilizados para detecção do câncer de mama. Entre eles a ressonância magnética, cuja principal desvantagem é o alto custo para sua realização, o que pode ser impeditivo em muitos casos ([BORCHARTT, 2013](#)).

A termografia infravermelha (TIR) é uma técnica de imageamento que pode ser utilizada na detecção do câncer de mama. A TIR é uma técnica de baixo custo e que não envolve radiação nociva ao ser humano. Ela se baseia no princípio de medir a radiação emitida por um objeto ou superfície, através de uma câmera infravermelha por exemplo, para determinar a sua temperatura ([KANDLIKAR et al., 2017](#)). Além do baixo custo do exame, a termografia pode proporcionar melhores resultados para detecção do câncer de mama em mulheres jovens, que geralmente possuem mamas mais densas, quando comparado à mamografia, não utiliza-se de radiações ionizantes, não envolve procedimentos invasivos e ainda é um procedimento indolor ([BORCHARTT et al., 2013](#)), ([NG, 2009](#)). Pesquisas indicam que essa técnica pode detectar o câncer de mama mais precocemente que outras técnicas, oferecendo o potencial de detectá-lo até anos antes da mamografia ([BORCHARTT et al., 2013](#)), ([NG, 2009](#)). O corpo humano, assim como todo corpo com temperatura acima do zero absoluto, emite energia térmica que pode ser convertida em temperatura. Essa energia pode ser obtida utilizando-se de uma câmera termográfica. As câmeras de infravermelho, ou câmeras termográficas, captam a radiação térmica emitida pelo corpo e a convertem numa imagem que representa a distribuição de temperaturas superficiais desse corpo ([ARAÚJO, 2009](#)), ([LELES et al., 2015](#)).

Quando existe uma anomalia no tecido da mama, como um tumor maligno ou mesmo algumas alterações benignas, há uma alteração na temperatura da superfície da mama. Especialmente no caso do tumor maligno, as células cancerígenas absorvem mais glicose e se reproduzem de forma desordenada. Dessa forma, o calor gerado por elas acarreta uma temperatura diferente do restante do corpo, a temperatura nessas regiões é mais quente, o que possibilita a identificação através das câmeras térmicas ([LELES et al., 2015](#)), ([ARAÚJO, 2009](#)).

Os primeiros trabalhos e relatos do uso da TIR para detecção do câncer de mama são da década de 50. Devido aos resultados ruins obtidos na época, a TIR acabou sendo deixada de lado, até que nos anos 2000, com os avanços tecnológicos nos equipamentos de câmeras infravermelhas, os pesquisadores voltaram a considerar o uso desta técnica de imageamento, que tem se mostrado uma técnica promissora ([KANDLIKAR et al., 2017](#)). Portanto pelos fatos expostos acima, a TIR configura-se como uma atraente técnica de auxílio à detecção precoce do câncer de mama.

## 1.2 Objetivos e Método de pesquisa

O objetivo deste trabalho foi desenvolver uma metodologia para realizar a análise de imagens termográficas catalogadas da mama classificando as imagens como normais, benignas ou malignas. Isso foi feito através da utilização de técnicas texturais e dimensão fractal para a extração das características das imagens e dos algoritmos classificadores Máquina de Vetores de Suporte (SVM) e Redes Neurais Artificiais (RNA).

Para alcançar o objetivo deste trabalho, os seguintes objetivos específicos foram buscados:

- Fazer uma bibliográfica sobre o uso de imagens termográficas para detecção do câncer de mama.
- Realizar pré-processamento das imagens a serem utilizadas para limpeza de informações que não são relevantes (regiões fora da mama) e extração da Regiões de Interesse (ROI).
- Selecionar, desenvolver e utilizar técnicas de extração de características nas imagens termográficas disponíveis na base sendo utilizada.
- Selecionar, desenvolver e utilizar algoritmos para classificação das imagens.
- Realizar experimentos buscando os melhores parâmetros para os algoritmos de classificação.
- Realizar experimentos para comparar os métodos desenvolvidos. Os experimentos desenvolvidos envolveram diferentes combinações possíveis das características extraídas e nos diferentes classificadores utilizados.

## 1.3 Resultados alcançados

Os resultados alcançados foram estudos e implementação de ferramentas automáticas para detecção do câncer de mama utilizando imagens termográficas. Foram implementados scripts em Matlab para cada etapa da metodologia. Além disso, estruturou-se a base de dados e separou-se as ROIs de cada imagem para que os próximos alunos tenham o caminho facilitado para continuar as pesquisas. Além disso, os scripts escritos em Matlab foram organizados e serão disponibilizados para a equipe coordenada pelo presente orientador.

## 1.4 Estrutura da monografia

Este trabalho está organizado da seguinte maneira: no capítulo 2 encontra-se o Referencial Teórico, capítulo que apresenta os conceitos fundamentais para entendimento deste trabalho; no capítulo 3 uma revisão da literatura na seção “Trabalhos correlatos” é apresentada. O capítulo 4 descreve os materiais e métodos utilizados e desenvolvidos nesta monografia. No capítulo 5 o detalhamento dos testes, os resultados obtidos e as discussões destes resultados são apresentados. Finalmente, no capítulo 6 encontra-se a conclusão e as perspectivas para trabalhos futuros.

## 2 Referencial teórico

Para o entendimento deste trabalho, o conhecimento de alguns conceitos e técnicas se faz necessário. Esses conceitos e técnicas serão apresentados neste capítulo. Este capítulo expõe conceitos relacionados à doenças na mama (entre elas o câncer de mama), métodos utilizados para detecção da doença, termografia infravermelha (TIR), técnicas computacionais de processamento de imagem e de aprendizado de máquinas e métodos de avaliação que serão utilizados no decorrer da monografia.

### 2.1 Câncer de mama

Câncer é o nome de um grupo de doenças que pode afetar diferentes órgãos do corpo e provoca a formação de tumores devido à um crescimento desregulado de células do corpo que podem se espalhar por várias partes do corpo (chamado metástase) (ARAÚJO, 2009), (KANDLIKAR et al., 2017). Células cancerígenas foram em algum momento células normais que sofreram algum tipo de deformação alterando seu funcionamento e provocando entre outros fatores a reprodução mais rápida e desordenada e maior consumo de glicose (LESSA; MARENGONI, 2016).

O termo tumor é utilizado para se referir a “um aumento de volume dos tecidos que pode não ser provocado por uma proliferação de células propriamente dita” (ARAÚJO, 2009). Tumores podem se referir a patologias benignas ou malignas. A diferença entre as duas pode ser definida em termos de grau de agressividade e comportamento biológico (ARAÚJO, 2009).

O câncer de mama, chamado de carcinoma, é uma das principais doenças que podem acometer a mama, junto com o fibroadenoma e as alterações fibrocísticas (BORCHARTT, 2013), (ALMEIDA et al., 2000). Existem mais de 20 tipos de câncer de mama identificados, entre eles carcinoma ductal, carcinoma lobular (a diferença entre esses dois tipos é a região do órgão onde começam) e câncer inflamatório (BORCHARTT, 2013), (KANDLIKAR et al., 2017). As alterações fibrocísticas e o fibroadenoma são alterações benignas. O primeiro pode se manifestar com a presença de cistos, dores e secreções. Já o fibroadenoma é o tipo de tumor benigno mais comum encontrado na mama que provoca o crescimento de nódulos e pode ser desenvolvido durante o período reprodutivo da mulher (BORCHARTT, 2013), (ARAÚJO, 2009), (ALMEIDA et al., 2000).

A mamografia é o procedimento padrão para o diagnóstico de câncer de mama (KANDLIKAR et al., 2017). Este procedimento, realizado com o uso de um mamógrafo, gera uma imagem da mama através da irradiação de raios-X (feixes ionizantes) de baixa

dosagem na mama da paciente. A mamografia detecta massas e calcificações na mama que podem ser indícios de câncer. Como em outras modalidades de exames que utilizam o raio-X, parte dos feixes dessa radiação é absorvida pelo tecido. Essa absorção é proporcional à densidade do tecido. Mamas formadas em sua maioria por tecido glandular denso acabam absorvendo muita radiação, aumentando as chances de problemas decorrentes do uso da radiação e ainda dificulta a visualização das calcificações, já que o tecido denso pode mascarar ou esconder as regiões cancerígenas (BORCHARTT, 2013), (ARAÚJO, 2009), (KANDLIKAR et al., 2017).

## 2.2 Termografia infravermelha

Uma outra técnica de imageamento que pode ser utilizada para a detecção de alterações na mama é a TIR. De acordo com Ibarra-Castanedo (2005), para se obter resultados relevantes através da TIR duas condições são necessárias: diferença de temperatura entre os objetos de interesse e equipamentos adequados para o imageamento termográfico. As imagens termográficas são imagens obtidas através de câmeras capazes de detectar radiação infravermelha. A Figura 1 - extraída de (SYSTEMS, 2014) - mostra uma câmera infravermelha.



Figura 1 – Exemplo câmera infravermelha Flir T460 - extraído de (SYSTEMS, 2014)

A lei de Stefan-Boltzmann afirma que a radiação emitida por um corpo é diretamente proporcional à quarta potência da temperatura absoluta (temperatura em Kelvin). Um corpo negro é um objeto que absorve toda a radiação incidente sobre ele e também reflete toda essa radiação, por isso é chamado de absorvedor e radiador perfeito. Portanto, nenhum outro objeto ou superfície pode emitir mais energia que o corpo negro. Sendo assim, o corpo humano e os demais objetos reais, emitem uma parte da radiação que o corpo negro emitiria nas mesmas condições. Essa relação entre a radiação emitida pelo objeto real e a que seria emitida pelo corpo negro é dada pela emissividade. A emissividade não é o único fator que influencia na TIR, como o imageamento não ocorre no vácuo, faz-se necessário considerar a transmissividade e refletividade do próprio objeto e ainda

a radiação refletida por outros objetos presentes no ambiente e a influência da atmosfera (transmissividade e refletividade) na imagem a ser coletada (IBARRA-CASTANEDO, 2005), (BORCHARTT, 2013).

O espectro infravermelho é uma das faixas do espectro eletromagnético. Essas faixas do espectro eletromagnético são definidas de acordo com o comprimento de onda. O espectro infravermelho abrange comprimentos de onda entre  $0.74$  e  $100\ \mu$ . Este espectro é situado entre os espectros da luz visível e das microondas, e é uma das bandas que compõem a radiação térmica (junto com o espectro visível e ultravioleta) (ARAÚJO, 2009), (BORCHARTT, 2013), (IBARRA-CASTANEDO, 2005). A radiação infravermelha não é visível a olho nu. A visualização no espectro infravermelho se dá por meio da chamada “imagem infravermelha” a qual pode ser obtida através de uma câmera termográfica (IBARRA-CASTANEDO, 2005). A Figura 2 (extraída de Ibarra-Castanedo (2005)) mostra o espectro eletromagnético. Nela podem ser observados os comprimentos de onda, o nome, a energia e frequência de algumas faixas do espectro eletromagnético com destaque para a radiação térmica e para o espectro infravermelho.




Figura 2 – Espectro eletromagnético - extraído de (IBARRA-CASTANEDO, 2005)

## 2.3 Processamento das imagens

### 2.3.1 Segmentação

A segmentação da ROI é uma das primeiras etapas no processamento e análise de imagens. É o processo que separa/particiona a imagem em regiões ou objetos nos quais se

está interessado, ou seja, consiste em separar os pixels da imagem em regiões distintas nas quais cada uma contém pixels com atributos similares. Desta forma, podem-se extrair as regiões a serem analisadas (ROIs) do restante da imagem (BORCHARTT, 2013), (VALA; BAXI, 2013), (BACKES, 2015). Os métodos de segmentação podem ser categorizados em dois grupos, segmentação baseada em aresta e segmentação baseada em região (VALA; BAXI, 2013). No primeiro, a segmentação se dá pela detecção de arestas ou bordas, buscando localizar pontos de mudanças abruptas na intensidade dos pixels. Esses pontos são ligados para formar os limites de objetos fechados. Esse método é ainda baseado em informações locais visto que arestas são características locais (VALA; BAXI, 2013), (PAL; PAL, 1993). A segunda abordagem tem a segmentação baseada em regiões semelhantes. Essa similaridade se dá por um critério específico, que é definido previamente. Desta forma, pixels semelhantes, baseado neste critério, pertencem ao mesmo grupo ou região. Um algoritmo que pertence a essa classe é o Otsu que será descrito na próxima subseção (VALA; BAXI, 2013).

A segmentação das imagens termográficas da mama tem como objetivo extrair apenas a mama (ROI) das imagens originais, descartando assim o fundo e também o restante do corpo da paciente, como por exemplo, os braços, axilas e abdômen. Quando se trata de segmentação das mamas, a ausência de um padrão no formato das mamas faz com que esta etapa se torne um desafio. Desta forma, diferentes níveis de automação são encontrados na literatura; entre elas técnicas completamente manuais, semi-automáticas ou completamente automáticas (BORCHARTT, 2013).

#### 2.3.1.1 Otsu

Otsu é uma das técnicas de segmentação de imagens por limiar (*threshold*) global baseadas em região amplamente utilizada na literatura devido à sua simplicidade e eficácia (VALA; BAXI, 2013). Algoritmos de *threshold* buscam selecionar valores de *thresholds* que sejam ótimos para separar os objetos de interesse da imagem (ZHANG; HU, 2008), (VALA; BAXI, 2013). Considerando dois grupos, o algoritmo de *threshold* produz uma imagem binária, onde os valores zero representam os pixels com valor de intensidade menor que o do *threshold* selecionado e um os pixels com valor de intensidade maior que *threshold* (VALA; BAXI, 2013). Esses algoritmos de *threshold* são classificados em dois grupos, *threshold* global (caso do Otsu) e *threshold* local. Algoritmos de *threshold* global são assim denominados por dependerem exclusivamente do valor do pixel. Já os algoritmos de *threshold* local dependem, além do valor do pixel, de alguma propriedade daquele pixel (VALA; BAXI, 2013).

O Otsu tem por objetivo maximizar a medida de separabilidade (variância) entre os diferentes grupos e minimizar a variância interna do grupo. Portanto, separar os pixels da imagem de forma que cada grupo seja internamente o mais homogêneo possível (com

intensidades de pixels semelhantes) e também que os grupos sejam entre si os mais heterogêneos possível (com intensidades de pixels diferentes) (BACKES, 2015), (PAL; PAL, 1993). Maximizando, dessa forma, a razão entre a variância entre classes e variância local (PAL; PAL, 1993).

A figura 3 extraída de (OTSU, 1979), ilustra um exemplo da aplicação do Otsu. A esquerda, a figura original pode ser encontrada, já a figura da direita ilustra a imagem depois da aplicação do Otsu.




Figura 3 – Imagem antes e depois da aplicação do Otsu - extraída de (OTSU, 1979)

A medida que o número de classes aumenta, Otsu tende demandar muito tempo porque utiliza a busca exaustiva para avaliar os critérios de maximização da variância entre classes, tornando-se inviável (VALA; BAXI, 2013).

### 2.3.2 Filtros

Os filtros são técnicas computacionais utilizadas para corrigir ou realçar características em uma imagem (THOMÉ, 2004). Como comumente as imagens que se deseja analisar apresentam ruídos devido aos mais variados motivos, por exemplo canais ruidosos pelos quais a imagem é transmitida ou erros de transmissão, filtros podem ser utilizados para corrigir (em parte ou em sua totalidade) essas imagens. Diversos filtros são encontrados na literatura. Como existem diferentes tipos de ruídos, os filtros corrigem tipos de ruídos específicos; então a performance de um filtro depende da imagem e do tipo de ruído encontrado nela (SUN; NEUVO, 1994). Outra aplicação dos filtros é realçar características na imagem, como por exemplo bordas (THOMÉ, 2004).

#### 2.3.2.1 Filtro de mediana

O filtro de mediana é um filtro não linear para reduzir ruídos do tipo impulsivos (ruídos que são aleatórios ou esparsos que estão presentes em apenas alguns pixels da imagem, por exemplo o "salt and pepper") (SUN; NEUVO, 1994), (MATHWORKS, 2017d). Neste tipo de filtro, uma vizinhança é definida e o valor de cada pixel é substituído pela mediana dos valores da sua vizinhança. É portanto um filtro invariante a

espaço que remove os ruídos mas em compensação borra as imagens. Quanto maior a vizinhança considerada no filtro, mais borrada será a imagem resultante o que pode acabar suavizando detalhes sutis da imagem (SUN; NEUVO, 1994), (THOMÉ, 2004).

A figura 4, extraída de (BACKES, 2015), ilustra a aplicação do filtro de mediana. A imagem da esquerda é a original com ruído. Já na imagem da direita o filtro de mediana com vizinhança 3x3 já foi aplicado, reduzindo drasticamente os ruídos.




Figura 4 – Exemplo da aplicação do filtro de mediana com vizinhança 3x3 - extraído de (BACKES, 2015)

#### 2.3.2.2 Filtro Gaussiano

O filtro gaussiano é um filtro que utiliza a função gaussiana para calcular os coeficientes das máscaras a serem aplicadas na imagem. Este filtro é normalmente utilizado para suavização das imagens porque desfoca a imagem e reduz ruídos (BACKES, 2015), (JESUS; JR, 2015). É calculado pela equação:

$$G(x, y) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(\frac{-(x^2 + y^2)}{2\sigma^2}\right) \quad (2.1)$$

onde  $\sigma$  é o desvio padrão do filtro gaussiano (DENG; CAHILL, 1993).

A figura 5, extraída de (JESUS; JR, 2015), demonstra a aplicação do filtro gaussiano. À esquerda se encontra a imagem original e à direita a imagem obtida após a aplicação do filtro gaussiano.

## 2.4 Descritores de Textura

Textura é um dos atributos visuais utilizados para identificar, descrever e classificar objetos e regiões de interesse em uma imagem. A textura está relacionada às propriedades físicas da imagem pois contém informações sobre o padrão da distribuição espacial das variações de tonalidade nas imagens dentro de uma banda (HARALICK; SHANMUGAM et al., 1973) e (BACKES; BRUNO, 2008).




Figura 5 – Exemplo da aplicação do filtro gaussiano - extraído de (JESUS; JR, 2015)

A palavra ‘fractal’ deriva da palavra em latim *fractus*, que significa segmentos irregulares (CHAUDHURI; SARKAR, 1995). A dimensão fractal é um valor real que representa a complexidade ou irregularidade geométrica de um dado objeto e se refere à quanto espaço este objeto ocupa (BACKES; BRUNO, 2008), (CHAUDHURI; SARKAR, 1995). A dimensão fractal pode ser utilizada para comparar diferentes texturas. Como na textura a complexidade é relacionada à organização dos pixels. A dimensão fractal pode quantificar a homogeneidade das texturas, possibilitando desta forma a comparação (BACKES; BRUNO, 2008).

## 2.5 Classificadores

Algoritmos de classificação são técnicas de aprendizado de máquina (subárea da inteligência artificial) (BORCHARTT, 2013). Os algoritmos de classificação podem ser subdivididos em diferentes grupos, de acordo com o tipo de aprendizado de cada um deles. Esses grupos podem ser supervisionado, não supervisionado ou aprendizado por reforço. No aprendizado supervisionado, a classificação dos dados, ou seja o resultado esperado (label), é conhecida. Portanto, o conjunto composto pela entrada e saída é passado ao algoritmo e o intuito é buscar padrões entre os membros de cada classe possibilitando que a classe de uma determinada instância seja encontrada. Já no caso do aprendizado não supervisionado apenas as entradas são conhecidas, as labels não estão disponíveis. Neste caso, a finalidade é buscar agrupamentos naturais no conjunto de entrada. No aprendizado por reforço há uma recompensa em caso de acerto e uma penalidade em caso de erro (BORCHARTT, 2013), (KOTSIANTIS; ZAHARAKIS; PINTELAS, 2006).

Os algoritmos de classificação utilizados neste trabalho serão supervisionados, já que a informação das classes de cada paciente é conhecida e precisa, conforme será descrito no capítulo 4. Cada registro (imagem) do banco de dados passa pelo processo de extração de características (sendo que todas essas instâncias devem ser representadas com o mesmo conjunto de características) (BORCHARTT, 2013), (KOTSIANTIS; ZAHARA-

KIS; PINTELAS, 2006). O conjunto dessas características extraídas será a entrada para os algoritmos de classificação, juntamente com a classe a qual aquela instância pertence. Há normalmente pelo menos duas etapas nos classificadores supervisionados: treinamento e teste. No treinamento, o classificador conhece as classes dos registros de entrada. A medida que os dados de treinamento vão sendo apresentados, um modelo que representa cada classe vai sendo elaborado. A partir dos modelos construídos na etapa do treinamento, os registros de teste são apresentados para o modelo, que classifica este novo registro (até então desconhecido), chamada fase de teste (BORCHARTT, 2013). Neste trabalho, os algoritmos de classificação utilizados são Máquina de Vetor de Suporte (SVM) e Redes Neurais Artificiais (RNA). As entradas para os métodos de classificação utilizados (SVM e RNA) serão características extraídas das imagens termográficas.

### 2.5.1 Máquina de Vetores de Suporte

SVM tornou-se popular devido a possibilidade de gerar modelos preditivos interpretáveis a partir da modelagem de situações não-lineares complexas (BORCHARTT, 2013). O objetivo do SVM é gerar um modelo baseado no princípio da indução que seja capaz de separar as classes minimizando o erro (número de elementos classificados erroneamente) (BORCHARTT, 2013). Esta técnica é uma técnica essencialmente binária (classifica apenas em duas classes diferentes). Para a resolução de problemas multiclasse utilizando SVM, podem combinar-se diversos classificadores binários, portanto reduzindo o problema à classificação binária (KOTSIANTIS; ZAHARAKIS; PINTELAS, 2006). Algumas técnicas para fazer essa redução dos problemas multiclasse em binários são um-contra-todos (*one-against-all* ou *one-versus-all*) e um-contra-um (*one-against-one* ou *one-versus-one*) (HSU; LIN, 2002).

Sejs  $k$  o número de classes. Na técnica um-contra-todos,  $k$  classificadores binários são gerados. Em cada um desses classificadores, uma classe é considerada positiva e as  $k-1$  restantes são consideradas negativas, de forma que todas as classes sejam a classe positiva para algum dos classificadores (HSU; LIN, 2002). Já na técnica um-contra-um são gerados  $\frac{k(k-1)}{2}$  classificadores binários. Cada classificador é treinado com uma combinação de duas classes, de forma que todas as possibilidades de combinar duas classes sejam exploradas (HSU; LIN, 2002). Diversos métodos para posteriormente testar esses SVM gerados são apresentados na literatura. Um deles, apresentado em Hsu e Lin (2002) utiliza o “Maior Vence” (*Max Wins*), onde a classe final é decidida pela estratégia de voto. A classe com maior número de votos é a eleita.

O SVM classifica os dados a partir da criação de hiperplanos de separação que diferenciem as classes. A partir dos dados de treinamento, o SVM cria um mapeamento desses dados para um novo espaço de maior dimensão chamado de espaço de características. Esse mapeamento acontece com o intuito de que os dados, agora espaço de características, se-

jam mais facilmente separáveis do que no espaço de características original (no espaço de entrada). Para uma melhor classificação, o SVM procura maximizar a distância entre os hiperplanos que separam as classes do problema (BORCHARTT, 2013), (ACHARYA et al., 2012). A figura 6, extraída de (LORENA; CARVALHO, 2007), ilustra esse conceito. Percebe-se que os dados da imagem formam um conjunto não linear (6.a). Na figura 6.b, encontra-se o espaço dos dados de entrada que precisam de uma função não linear para separar as duas classes. Já na figura 6.c, o espaço de características (cuja dimensão é maior que o espaço de entrada) é representando, e nele, a fronteira linear se faz possível.




Figura 6 – Ilustração dados não lineares, espaço de entrada e espaço das características. - extraído de (LORENA; CARVALHO, 2007)

Como o número de dimensões do espaço de características necessários para separar linearmente as classes pode ser muito alto, uma separação linear pode ser inviável (LORENA; CARVALHO, 2007), (BORCHARTT, 2013). Desta forma, as funções kernel foram introduzidas. As funções kernel são funções que dados dois pontos do espaço de entrada, calculam o produto escalar deles no espaço de características. Entre as funções kernel encontradas na literatura estão: função gaussiana, polinomial e sigmoideal (LORENA; CARVALHO, 2007).

## 2.5.2 Redes Neurais Artificiais

Outra maneira de se realizar a classificação e o reconhecimento de padrões é utilizando redes neurais. Redes neurais são modelos computacionais baseados no sistema nervoso de animais. Uma rede neural é constituída de neurônios organizados em camadas e conectados entre si por conexões denominadas pesos sinápticos. Existem uma variedade de tipos de redes neurais, algumas das diferenças entre elas estão em como os neurônios estão conectados e no algoritmo utilizado para correção dos pesos sinápticos (LESSA; MARENGONI, 2016), (KOTSIANTIS; ZAHARAKIS; PINTELAS, 2006).

O perceptron é o tipo mais simples de uma rede neural que classifica apenas instâncias de problemas linearmente separáveis e é também uma técnica binária. O perceptron é composto de um neurônio e uma função de ativação. Cada entrada do perceptron, corresponde à um atributo do problema e existe ainda uma entrada chamada de bias (é um threshold). A saída do perceptron é binária, sendo que 0 corresponde a uma determinada classe e 1 corresponde a outra classe (KOTSIANTIS; ZAHARAKIS; PINTELAS, 2006). A figura 7, extraída de (CASTRO, 2012) ilustra um perceptron. Nesta figura, a entrada com o valor +1 é a bias,  $w$  são os pesos,  $x$  são as entradas,  $y$  a saída e  $f(u)$  a função de ativação.




Figura 7 – Ilustração de um perceptron - extraída de (CASTRO, 2012)

Uma rede neural multi-camadas consiste em vários neurônios conectados que são separados em pelo menos três camadas: camada de entrada (*input layer*), camada na qual os neurônios recebem a informação, camada de saída (*output layer*), camada cuja saída é a saída da rede e as camadas escondidas (*hidden layers*) (KOTSIANTIS; ZAHARAKIS; PINTELAS, 2006). Ainda de acordo com Kotsiantis, Zaharakis e Pintelas (2006), alguns aspectos são fundamentais para o bom desempenho das redes neurais. São eles: arquitetura da rede, visto que o número de neurônios das camadas escondidas pode levar a *overfitting* (modelo não genérico, com excelentes resultados para o conjunto de treinamento e/ou teste, mas resultados pobres para outras entradas) ou modelos com aproximações e generalizações ruins; peso das conexões entre os neurônios, valor que vai determinar o comportamento da rede; função de ativação e as entradas. Nas redes neurais supervisionadas há a separação entre dados para treinamento e teste, como ocorre no SVM. Durante a etapa de treinamento, as entradas são colocadas na rede, que calcula a saída para aquela dada entrada. A saída da rede é então comparada com o valor esperado. Baseado nesta comparação, a rede neural vai adaptando o valor dos pesos buscando aproximar cada vez mais a saída da rede dos resultados esperados. A figura 8 ilustra uma rede neural multi-camadas com ‘m’ neurônios de entrada, ‘o’ neurônios de saída, duas camadas ocultas e cujos neurônios estão ligados através dos pesos.




Figura 8 – Ilustração de uma rede neural com duas camadas ocultas - extraída de (CASTRO, 2012)

### 2.5.3 Métodos de avaliação dos classificadores

Um método de amostragem frequentemente empregado para avaliação quando faz-se o uso de algoritmos de classificação é a validação cruzada. O uso da validação cruzada garante que amostras diferentes sejam utilizadas para treinamento e teste nos métodos de classificação visto que conjuntos mutuamente exclusivos para essas etapas são elaborados. Entre os casos especiais da validação cruzada estão o *k-fold* e o *Leave-one-out*. No *k-fold*, a amostra inicial (todos os dados disponíveis para análise) é aleatoriamente dividida em  $k$  subconjuntos. Esses  $k$  subconjuntos são separados em  $k-1$  subconjuntos para serem utilizados na etapa de treinamento e um subconjunto para o teste. Isso é feito  $k$  vezes, de modo que todos os subconjuntos sejam em alguma execução, o subconjunto de teste. Já *Leave-one-out* é um caso particular do *k-fold* no qual cada subconjunto de teste equivale a uma única instância. Tem-se portanto neste caso que  $k$  é igual ao número de instâncias da amostra (KOTSIANTIS; ZAHARAKIS; PINTELAS, 2006), (BORCHARTT, 2013).

Para avaliação dos resultados obtidos pelas técnicas de classificação serão utilizadas as medidas de acurácia, sensibilidade e especificidade. A acurácia diz respeito à proporção de instâncias corretamente classificadas (considerando-se todas as classes) e é calculada pela expressão 1. Já a sensibilidade diz respeito à proporção de casos cancerígenos corretamente classificados como cancerígenos e é calculada pela expressão 2. A especificidade diz respeito à proporção de casos normais (sem câncer) corretamente classificados como normais e é calculada pela expressão 3. Todas as expressões foram extraídas do trabalho em Borchartt (2013). Em imagens médicas, a seguinte nomenclatura é adotada: Verdadeiro Positivo (VP) é o número de casos doentes classificados corretamente como casos doentes; Verdadeiro Negativo (VN) é o número de casos saudáveis classificados corretamente como casos saudáveis; Falso Positivo (FP) é o número de casos saudáveis que foram incorretamente classificados como casos doentes; Falso Negativo (FN) é o número de casos doentes incorretamente classificados como casos saudáveis (BORCHARTT, 2013).

$$Acurácia = \frac{VP + VN}{VP + FP + VN + FN}$$

Expressão 1 - Cálculo da Acurácia extraído de (BORCHARTT, 2013)

$$Sensibilidade = \frac{VP}{VP + FN}$$

Expressão 2 - Cálculo da Sensibilidade extraído de (BORCHARTT, 2013)

$$Especificidade = \frac{VN}{VN + FP}$$

Expressão 3 - Cálculo da Especificidade extraído de (BORCHARTT, 2013)

Outra maneira importante para avaliar os resultados dos algoritmos de classificação é a curva de característica de operação do receptor (ROC - Receiver Operating Characteristic). O ROC é um gráfico bidimensional que tem no eixo Y o valor do VP e no eixo X o valor do FP. Portanto, a relação entre a sensibilidade e os FP é estabelecida de maneira gráfica (BORCHARTT, 2013), (FAWCETT, 2006). A partir da ROC, pode-se gerar um outro método para validar os resultados, a área sob a curva ROC. Este valor é um número real entre 0 e 1 e quanto mais perto de 1, melhor foi a classificação (BORCHARTT, 2013).

## 3 Revisão Bibliográfica

### 3.1 Trabalhos correlatos

Há na literatura diversos trabalhos que utilizam-se de imagens termográficas da mama para identificar presença de tumores malignos ou alterações na mama que podem ser benignas ou malignas. Esses trabalhos variam principalmente na forma como a extração das características foi realizada. Com relação ao classificador utilizado, a máquina de vetores de suporte (SVM) tem se mostrado o mais comum.

Em [Borchardt \(2013\)](#) foi desenvolvida uma metodologia para identificar a presença ou ausência de alterações na mama, não classificando a presença em maligna ou benigna. A base de dados utilizada foi composta de imagens termográficas de 69 pacientes adquiridas pelo protocolo estático, sendo 19 pacientes saudáveis e 50 com alguma patologia. As imagens foram obtidas de duas bases de dados públicas da Universidade Federal de Pernambuco (UFPE) e da Universidade Federal Fluminense (UFF) e em ambas os laudos de especialistas são disponíveis. Neste trabalho, houve o pre-processamento das imagens termográficas para obtenção de imagens limpas através do *Software Development Kit (SDK)* da Flir. Para correções relacionadas à posição das pacientes após a coleta das imagens foram utilizadas técnicas de registro de imagens e transformações geométricas. A extração das Regiões de Interesse (ROIs) foi realizada de forma automática através de um *software* e/ou do aplicativo *Groud Truth Maker*. Diversas técnicas diferentes foram utilizadas para extração de características, sendo elas: características extraídas de medidas estatísticas, características extraídas dos histogramas, dimensão fractal e características extraídas de métodos de geoestatística adaptadas do estudo de análises espaciais de terrenos; as características obtidas foram também combinadas entre si para fins de comparação. A classificação foi realizada através do classificador SVM e otimizadas por algoritmos genéticos. As medidas utilizadas para validar a classificação foram especificidade, sensibilidade, acurácia, área sobre a curva ROC e o índice de Youden e os resultados obtidos foram especificidade de 79%, sensibilidade de 92%, acurácia de 88%, área sob a curva ROC de 0,852 e índice de Youden de 0,705.

Diferentemente do trabalho de [Borchardt \(2013\)](#), em [Okuniewski et al. \(2016\)](#) é apresentada uma abordagem para decidir sobre a presença ou não de câncer em imagens termográficas. As imagens termográficas utilizadas foram obtidas a partir do aparelho Braster. O Braster é um aparelho desenvolvido recentemente para obtenção de imagens termográficas da mama que de acordo com os autores, pode ser utilizado como primeiro passo para a detecção de câncer. As imagens extraídas por este dispositivo são processadas por uma aplicação web que possui duas etapas de classificação, ambas realizadas

com quatro diferentes classificadores: *Naive Bayes*, Árvores de decisão, *Random Forest* e SVM. Inicialmente, o pré-processamento das imagens é realizado, este consiste na conversão das imagens para HSV (espaço de cor que define as cores em termos de tonalidade ou matiz, saturação e valor ou brilho. Tonalidade é o componente da cor, relacionada ao comprimento de onda da luz que define a cor do objeto; saturação refere-se ao grau de “pureza” da cor; valor ou brilho relacionado ao brilho - quantidade de luz - da cor (PONTI-JR, 2012)), enquadramento, segmentação e operações de processamento de imagens morfológicas e discretização (para os três primeiros classificadores mencionados). O resultado do pré-processamento é o que os autores chamaram de contornos, que são áreas de hipertermia (esta pode ser um indício da presença do câncer, porém este não é o único fator que causa essa alteração). Os contornos, descritos por atributos relacionados a geometria, área, temperatura e curvatura são então classificados em patológicos ou não pelos quatro classificadores na etapa chamada de classificação de contornos. Ao resultado desta etapa são acrescentados alguns outros atributos (relacionados à assimetria da imagem e informações obtidas pelos pacientes) que são classificados na etapa denominada classificadores de pacientes, estes então determinam o resultado final da análise. Duas bases de dados foram utilizadas, a primeira continha 229 imagens, 180 sem patologias e 49 com; desta, 2453 contornos foram extraídos, sendo apenas 63 patológicos. Na segunda, um acréscimo de 96 imagens patológicas foi feito resultando em um total de 325 imagens. Após a extração dos contornos, foram obtidos 2776 destes, sendo apenas 161 patológicos. Como a base utilizada é desbalanceada, técnicas para fazer o balanceamento foram utilizadas. Cada classificador apresentou diferentes resultados, as *Naive Bayes* apresentaram altas especificidades, enquanto o SVM apresentou altas sensibilidades, as *Random Forest* apresentaram bons resultados para especificidade e sensibilidade e as árvores de decisão apresentaram resultados insatisfatórios.

Acharya et al. (2012) também propôs um sistema que classifica os termogramas da mama em malignos ou normais. Este sistema utiliza algumas características de textura extraídas das matrizes de co-ocorrência e *run-length* escolhidas com base no *t-test* e *p-value*, as características escolhidas são as que tem baixos p-values; são elas momento1, momento3, run percentage, e escala de cinza não-uniforme. O classificador escolhido foi SVM com método de validação *three-fold stratified cross validation*. A base de dados utilizada contém 50 termogramas, sendo 25 normais e 25 malignos, destes malignos, apenas os estágios II e III do câncer estavam presentes. Antes da extração das características, há um pré-processamento que converte a imagem para escala de cinza e corta/separa as mamas direita e esquerda em arquivos diferentes. Os resultados obtidos foram de 88.10% para acurácia, 85.71% para sensibilidade e 90.48% especificidade.

No trabalho desenvolvido por Madhu et al. (2016) é proposto um sistema automático para diferenciar tumores malignos de outras condições não malignas que causam aquecimento localizado na mama. Este sistema busca aumentar a especificidade nas aná-

lises das imagens termográficas, visto que essa medida apresenta na maioria dos trabalhos resultados muito inferiores a sensibilidade. Isso é feito utilizando como características a presença de regiões anormais (que são regiões que apresentam aumento significativo de temperatura comparado com suas regiões vizinhas), temperatura relativa, comparação de temperatura de mamas contralaterais, e as margens/bordas. Um diferencial desse trabalho para a maioria dos demais é que a extração das características não é feita das ROI inteiras e sim de regiões consideradas anormais dentro da ROI que está sendo considerada. A base de dados considerada continha dados de 265 pacientes, sendo 120 com mamas normais, 78 com anomalias malignas e 67 anomalias benignas, lactantes e tecidos sensíveis à hormônio. Os resultados apresentados tem especificidade de 98.9% e sensibilidade 100%. Este trabalho também aplica as características propostas em [Acharya et al. \(2012\)](#) e os resultados foram 57.5% e 73 % para sensibilidade e especificidade respectivamente. Uma ressalva deste trabalho é que a metodologia parece ser muito específica para a base de dados que eles utilizaram, portanto, caso as mesmas técnicas sejam aplicadas a outras bases de dados, os resultados atingidos pelos autores possivelmente não serão obtidos.

[Lessa e Marengoni \(2016\)](#) apresentam outro sistema que classifica as imagens termográficas em normais e com anomalias utilizando-se de características estatísticas e Redes Neurais Artificiais (RNA). As características consideradas foram: média, mediana, variância, desvio padrão, assimetria, curtose, entropia e intervalo. A base de dados foi composta de imagens de 47 pacientes diferentes, portanto, imagens de 94 mamas foram consideradas, sendo elas 48 mamas normais e 46 mamas com anomalias. Estas imagens foram extraídas da base DMR (*Database for Mastology Research*). Duas estruturas diferentes de RN foram testadas, ambas com 8 entradas (correspondendo às 8 características consideradas). A primeira opção testada foi uma RNA que resolve problemas lineares, esta não apresentou resultados consideráveis. A segunda, que resolve problemas não lineares, contava com a entrada, saída com 2 neurônios (uma saída para cada classe - normal e com anomalia) e uma camada escondida com 5 neurônios (número de neurônios foi decidido fazendo a média da quantidade de neurônios das camadas de entrada e saída). Esta segunda abordagem utilizava o algoritmo *back-propagation* para correção dos pesos e apresentou resultados promissores, com 87% de sensibilidade, 83% de especificidade e 85% de acurácia.

[Leles et al. \(2015\)](#) desenvolveram um trabalho que classifica as imagens termográficas da mama em três grupos distintos, normais (sem patologias), com patologia benigna e com patologia maligna (câncer). A classificação obtida pela análise da imagem termográfica é comparada ao resultado de um ou mais dos seguintes exames: clínico, mamografia e ultrassonografia e biopsia, dependendo da disponibilidade de dados desses procedimentos para cada paciente. A base de dados utilizada é composta por 70 pacientes, sendo que para algumas pacientes (com diagnóstico normal) imagens de ambas as mamas foram consideradas, enquanto para as pacientes com patologias (tanto benignas quanto malignas)

apenas a imagem da mama com a patologia foi considerada. Para obtenção das ROI, as imagens passaram pelas etapas de pré-processamento, segmentação e refinamento manuais. A classificação das ROIs foi realizada com o uso da dimensão fractal pelo método de análise de textura *BoxCounting*. Os autores geraram ainda histogramas correspondentes para cada um dos grupos obtidos e a partir destes histogramas, características foram extraídas. As características utilizadas foram valor mínimo e máximo, moda curtose e desvio padrão. Os autores perceberam que cada grupo tem um histograma característico, sendo que o histograma das patologias (tanto benigna quanto maligna) tem formato mais distribuído e médias mais baixas que o histograma das imagens normais e o histograma das imagens malignas apresenta formato mais assimétrico. Para avaliação dos resultados, os autores consideraram sensibilidade, especificidade (valores obtidos foram respectivamente 92,3% e 86,2%), valor preditivo positivo (VPP), valor preditivo negativo (VPN) (obteve-se respectivamente 85,7% e 92,5%), Razão de Probabilidade Positiva (RPP) e Razão de probabilidade negativa (RPN) (cujos resultados foram respectivamente 6,68 e 0,089).

Baseado nestes trabalhos da literatura, percebe-se que há poucos trabalhos que visam classificar uma base de imagens termográficas em três classes diferentes (normais, benignas e malignas) como é o objetivo deste trabalho. A maioria dos artigos adota classificação binária, seja ela com ausência ou com presença do câncer (no caso da ausência, tanto pacientes normais e quanto com alterações benignas pertenceriam a esta classe) ou com alteração (benigna ou maligna) ou normais.

## 4 Materiais e métodos

Neste capítulo serão descritas a base de dados utilizada, com detalhes da coleta dos dados e as etapas da metodologia utilizadas para classificar as pacientes em normal, com alteração benigna ou com alteração maligna. O fluxograma da figura 12 ilustra as etapas da metodologia adotada.




Figura 12 – Etapas da metodologia

### 4.1 Base de dados

A base de dados utilizada contém dados de 70 pacientes portadoras ou não de nódulos mamários adquiridas por [Leles et al. \(2015\)](#). Estas imagens foram coletadas no Hospital e Maternidade Dr. Odelmo Leão Carneiro entre outubro de 2013 e fevereiro de 2014. A coleta foi realizada com o equipamento *FLIR T420 Thermal Imaging InfraRed Camera* que produz imagens de dimensão 320 x 240 pixels onde cada pixel representa um valor de temperatura. De acordo [Leles et al. \(2015\)](#), a coleta das imagens foi realizada utilizando-se do protocolo estático, no qual a paciente aguarda 15 minutos para aclimatização da temperatura corporal e em seguida a coleta de imagens é realizada (para

mais informações sobre a coleta das imagens vide [Leles et al. \(2015\)](#)). As coletas das imagens foram realizadas em quatro poses diferentes: frontal com os braços levantados, frontal com os braços abaixados, lateral esquerda (somente da mama esquerda) e lateral direita (somente da mama direita). Para as análises realizadas nesta monografia, foram consideradas apenas as imagens frontal com os braços levantados.

As pacientes foram classificadas em três grupos: normais (sem alterações), com patologia benigna (nódulos benignos) e com patologia maligna (tumores). A classificação de cada paciente foi obtida através do diagnóstico do médico especialista baseado nos exames: mamografia, ultrassonografia, ressonância magnética e biópsia. Entretanto, algumas pacientes não foram submetidas a todos os exames. As pacientes foram submetidas apenas aos exames necessários para que o médico especialista tivesse o diagnóstico conclusivo e final ([LELES et al., 2015](#)). As 70 pacientes consideradas estão divididas da seguinte forma: 21 pacientes sem alterações na mama (normal), 23 com alterações benignas e 26 com alterações malignas.

As figuras 13, 14 e 15 contém três imagens da base de dados das classes normal, benigno e maligno respectivamente.




Figura 13 – Exemplo de imagem de paciente normal




Figura 14 – Exemplo de imagem de paciente com tumor benigno




Figura 15 – Exemplo de imagem de paciente com tumor maligno

## 4.2 Pré-processamento e segmentação das imagens

As imagens termográficas da base de dados estão no formato .jpg. Esses arquivos possuem os valores de temperatura de cada pixel da imagem e ainda alguns metadados, entre eles parâmetros considerados na captura das imagens e informações das imagens (por exemplo, temperatura mínima e máxima da imagem). Utilizando-se do software *Flir Tools* + disponibilizado pela fabricante da câmera termográfica utilizada, foi possível exportar os valores de temperatura que formam a imagem para um arquivo .csv. Esse arquivo pode ou não ter os metadados (opções que o sistema oferece). Para esta monografia os metadados não foram utilizados. Para cada imagem, um arquivo csv foi gerado contendo os valores de temperatura de cada região da imagem. Esses arquivos foram importados no Matlab gerando assim as matrizes que foram utilizadas para processamento e segmentação das imagens.

O processo de segmentação das imagens foi realizado de maneira semi-automática. Inicialmente, as regiões que contém cada uma das mamas foram cortadas, gerando assim novas imagens menores contendo apenas uma das mamas e consequentemente o dobro de imagens foi produzido. Posteriormente, para segmentar apenas as mamas dessas novas imagens utilizou-se o algoritmo Otsu. A escolha do número de classes utilizadas para a segmentação das imagens foi realizada de maneira empírica e específica para cada mama com o objetivo de obter a melhor separação entre a mama e as demais regiões da imagem. De acordo com as classes resultantes da aplicação do Otsu, máscaras binárias foram gera-

das. Em alguns pacientes, ajustes manuais para a geração das máscaras foram necessários já que as classes resultantes da aplicação do Otsu não foram suficientes para separar a ROI (mama) do restante da imagem. Isso se deve aos fatores mencionados na seção 2.1.3 e ainda, devido à qualidade das imagens, e à diferença entre as temperaturas de alterações nas mamas e o restante do órgão. Ao final desse processo, 140 imagens foram obtidas e 140 máscaras binárias foram geradas.

A figura 16 ilustra cada etapa do pré-processamento para a paciente 57. A primeira imagem (imagem 1) contém a imagem original importada no Matlab, já as duas imagens da segunda etapa (imagem 2A e 2B) contém as imagens cortadas para conter apenas a região da mama, uma imagem para a mama direita e uma para a mama esquerda. As duas imagens da terceira etapa (imagem 3A e 3B) são o resultado da aplicação do algoritmo do Otsu; cada cor representa uma classe. As próximas duas imagens (imagem 4A e 4B) são as máscaras iniciais geradas com base nas classes dos Otsu. As duas imagens seguintes (imagem 5A e 5B) contém as máscaras finais após os ajustes manuais. As últimas imagens (imagem 6A e 6B) contém a máscara aplicada nas imagens da segunda etapa. São dessas últimas imagens que as características são extraídas. Embora a segmentação apenas com o Otsu não seja suficiente para segmentar a imagem de forma adequada, a máscara final oferece uma segmentação adequada para as demais etapas da metodologia.




Figura 16 – Ilustração das etapas do pré-processamento para paciente 57

### 4.3 Extração das características

Após a segmentação e extração das ROI, características foram extraídas destas imagens. A extração de características busca obter informações das imagens que possam descrevê-las de forma eficaz e que o especialista apenas olhando as imagens não perceberia.

Foram utilizadas as características apresentadas na tabela 1. A escolha dessas características foi baseada majoritariamente nos trabalhos de (BORCHARTT, 2013), (ACHARYA et al., 2012), (LESSA; MARENGONI, 2016). Para cada mama (direita e esquerda) foram extraídas essas características.

Diversas combinações de características diferentes foram obtidas a partir das 17 características mencionadas. Cada combinação foi utilizada como entrada dos classificadores para encontrar o melhor conjunto de características adequados à base de dados utilizada. Em seguida, cada uma dessas características é descrita resumidamente. Para o cálculo destas características, utilizou-se, em sua maioria, funções já disponibilizadas

| Grupo                                                            | Número | Característica        |
|------------------------------------------------------------------|--------|-----------------------|
| Medidas estatísticas                                             | 1      | Média                 |
|                                                                  | 2      | Desvio Padrão         |
|                                                                  | 3      | Mediana               |
|                                                                  | 4      | Temperatura Mínima    |
|                                                                  | 5      | Temperatura Máxima    |
|                                                                  | 6      | Amplitude Térmica     |
|                                                                  | 7      | Assimetria            |
|                                                                  | 8      | Curtose               |
|                                                                  | 9      | Entropia              |
| Medidas estatísticas obtidas a partir da matriz de Co-ocorrência | 10     | Contraste             |
|                                                                  | 11     | Correlação            |
|                                                                  | 12     | Homogeneidade         |
|                                                                  | 13     | Energia               |
| Momento estatístico                                              | 14     | Momento 2             |
|                                                                  | 15     | Momento 3             |
|                                                                  | 16     | Momento 4             |
| Dimensão Fractal                                                 | 17     | Dimensão Box-Counting |

Tabela 1 – Características extraídas das mamas

pelo Matlab, como por exemplo funções de *mean* e *max*, para cálculo da média e temperatura máxima; o script para cálculo do box-counting disponível em (MOISY, 2008); e ainda scripts próprios, para o caso da amplitude térmica.

### 4.3.1 Medidas estatísticas

#### 4.3.1.1 Média

Média é o valor que indica onde os dados da distribuição mais se concentram. A média nas imagens termográficas, indica a temperatura global da ROI (mama) (BORCHARTT, 2013), (LESSA; MARENGONI, 2016). A média é calculada pela equação (4.1):

$$\bar{t} = \frac{1}{n} \sum_{i=1}^n t_i \quad (4.1)$$

onde  $\bar{t}$  é a média,  $n$  é o número total de pixels da imagem e  $t_i$  o valor de temperatura pixel  $i$ .

#### 4.3.1.2 Desvio Padrão

Desvio padrão é o valor que indica a dispersão dos dados em torno da média. Um desvio padrão baixo revela que os valores estão próximos da média, revelando maior homogeneidade na imagem; já um alto desvio padrão revela grande dispersão e portanto maior heterogeneidade na imagem (BORCHARTT, 2013), (LESSA; MARENGONI, 2016). O

desvio padrão é calculado pela equação (4.2):

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (t_i - \bar{t})^2} \quad (4.2)$$

onde  $\sigma$  é a o desvio padrão,  $n$  é o número total de pixels da imagem,  $t_i$  o valor de temperatura pixel  $i$  e  $\bar{t}$  é a média.

#### 4.3.1.3 Mediana

Mediana é o valor que divide a probabilidade da distribuição em duas partes iguais, ou seja, o valor central da distribuição. Como existe simetria entre as duas mamas, quanto maior a diferença entre as medianas das mamas, maior a chance de anomalia; e quando menor a diferença entre elas, menor a chance de anomalia (LESSA; MARENGONI, 2016).

Para calcular a mediana, os valores de temperatura de todos os pixels são ordenados em ordem crescente e verifica-se o valor do meio (caso o número de pixels seja ímpar) ou os dois termos centrais (caso o número de pixels seja par).

#### 4.3.1.4 Temperatura Mínima

Temperatura Mínima é o menor valor de temperatura da ROI. É calculado pela equação (4.3):

$$t_{min} = \min_{0 < i \leq n} t_i \quad (4.3)$$

onde  $t_{min}$  é a temperatura mínima,  $n$  é o número total de pixels e  $t_i$  o valor de temperatura pixel  $i$ .

#### 4.3.1.5 Temperatura Máxima

Temperatura Máxima é o maior valor de temperatura da ROI. É calculado pela equação (4.4):

$$t_{max} = \max_{0 < i \leq n} t_i \quad (4.4)$$

onde  $t_{max}$  é a temperatura máxima,  $n$  é o número total de pixels e  $t_i$  o valor de temperatura pixel  $i$ .

#### 4.3.1.6 Amplitude Térmica

A amplitude térmica é uma medida de dispersão cujo valor que indica a variação máxima da temperatura na mama (BORCHARTT, 2013), (LESSA; MARENGONI, 2016). É calculado pela equação (4.5):

$$\Delta t = \max_{0 < i \leq n} t_i - \min_{0 < i \leq n} t_i \quad (4.5)$$

#### 4.3.1.7 Assimetria

Assimetria é o valor que indica o afastamento da variável em relação à média, ou seja, o desvio das temperaturas em torno da temperatura média (FARIA, 2017). Quando a assimetria é positiva, os dados estão mais espalhados à direita da média, quando ela é negativa, os dados estão mais espalhados à esquerda da média. Quando a distribuição é perfeitamente simétrica, o valor da assimetria é zero (MATHWORKS, 2017f), (LESSA; MARENGONI, 2016). É calculado pela equação (4.6):

$$s = \frac{E(t_i - \bar{t})^3}{\sigma^3} \quad (4.6)$$

onde  $s$  é a assimetria,  $t_i$  é a temperatura do pixel  $i$ ,  $\bar{t}$  é a média,  $\sigma$  o desvio padrão e  $E$  a esperança.

#### 4.3.1.8 Curtose

Curtose é o valor que representa o grau de achatamento da curva da distribuição com relação a distribuição normal (FARIA, 2017). É calculado pela equação (4.7) (MATHWORKS, 2017c):

$$k = \frac{E(t_i - \bar{t})^4}{\sigma^4} \quad (4.7)$$

onde  $k$  é o curtose,  $t_i$  é a temperatura do pixel  $i$ ,  $\bar{t}$  é a média,  $\sigma$  o desvio padrão e  $E$  a esperança.

#### 4.3.1.9 Entropia

Entropia é o valor que mede a informação contida nas imagens e a quantidade de desordem na ROI. A entropia está relacionada a simetria da imagem, quanto menor a entropia, mais simétrica é a imagem. Quando a entropia entre as mamas difere bastante, a assimetria das mama é alta, consequentemente existe uma probabilidade maior de anomalia (LESSA; MARENGONI, 2016). É calculada pela equação (4.8) (MATHWORKS, 2017a):

$$H = - \sum_{i=1}^n p_i * \log_2(p_i) \quad (4.8)$$

onde  $H$  é a entropia,  $n$  o número total de pixels da imagem e  $p_i$  é o valor da contagem do histograma normalizado do pixel  $i$ .

### 4.3.2 Medidas estatísticas obtidas a partir da matriz de co-ocorrência de nível de cinza

A matriz de co-ocorrência de nível de cinza é uma matriz cujos valores correspondem a frequência na qual um par de pixels com valores específicos ocorrem na imagem. Ou seja, com que frequência o valor do pixel  $i$  ocorre horizontalmente, verticalmente ou diagonalmente aos pixels adjacentes com valor  $j$  (MATHWORKS, 2017g), (HAYER, 2017).

#### 4.3.2.1 Contraste

Contraste é uma medida que indica as variações locais na matriz de co-ocorrência de nível de cinza. É o valor que indica a intensidade do contraste entre um pixel da imagem e seus vizinhos em toda a imagem. Contraste zero indica uma imagem constante. O contraste é calculado pela equação (4.9) (MATHWORKS, 2017g), (MATHWORKS, 2017b), (ACHARYA et al., 2012):

$$con = \sum_{i,j=1}^n |i - j|^2 p(i, j) \quad (4.9)$$

onde  $i$  e  $j$  são posições de pixels na matriz e  $p(i, j)$  é o valor do pixel da posição  $i$  e  $j$  na matriz de co-ocorrência.

#### 4.3.2.2 Correlação

A correlação é uma medida que indica a ocorrência da probabilidade conjunta em pares de pixels específicos. Indica quão correlacionado é um pixel com relação aos seus vizinhos em toda a imagem. A correlação de uma imagem perfeitamente correlacionada é 1 ou -1 (para perfeitamente correlacionada positivamente ou negativamente) (MATHWORKS, 2017g), (MATHWORKS, 2017b), (ACHARYA et al., 2012). A correlação é calculada pela equação (4.10):

$$cor = \sum_{i,j=1}^n \frac{(i - \mu_i)(j - \mu_j)p(i, j)}{\sigma_i \sigma_j} \quad (4.10)$$

#### 4.3.2.3 Homogeneidade

A homogeneidade é a medida da proximidade da distribuição de elementos da matriz de co-ocorrência de nível de cinza para a diagonal da mesma (MATHWORKS, 2017g), (MATHWORKS, 2017b). É calculada pela equação (4.11):

$$homog = \sum_{i,j=1}^n \frac{p(i, j)}{1 + |i - j|} \quad (4.11)$$

#### 4.3.2.4 Energia

A energia é a soma quadrada dos elementos da matriz de co-ocorrência de nível de cinza. (MATHWORKS, 2017g), (MATHWORKS, 2017b). É calculada pela equação (4.12):

$$ener = \sum_{i,j=1}^n p(i, j)^2 \quad (4.12)$$

#### 4.3.3 Momento estatístico

O momento de uma distribuição de ordem k é definido como esperança de  $x^k$ . Momentos centrais, são baseados nos desvios em relação a média (FORSTER, 2017). São definidos pela equação (4.13):

$$m_k = E(p - \bar{p})^k \quad (4.13)$$

Como características para este trabalho, foram considerados k = 2, 3 e 4; portanto, momento 2, momento 3, momento 4 (ACHARYA et al., 2012), (MATHWORKS, 2017e).

#### 4.3.4 Dimensão Fractal

Como a dimensão fractal possibilita quantificar a homogeneidade das texturas (BACKES; BRUNO, 2008), foi utilizada como uma das características consideradas. Existem diversas técnicas e algoritmos para calcular a dimensão fractal. Neste trabalho a dimensão fractal considerada foi obtida pelo método Box Counting (LELES et al., 2015).

##### 4.3.4.1 Dimensão Box Counting

O método Box Counting divide a imagem em quadrados de tamanhos iguais r e contando em quantos destes quadrados a ROI está presente N(r). Esse processo é repetido várias vezes diminuindo-se o tamanho dos quadrados. A inclinação da curva que melhor se ajusta ao gráfico do logaritmo do número de quadrados que contém a ROI pelo logaritmo do tamanho dos quadrados é o resultado da dimensão fractal, também chamada dimensão box counting (TAVAKOL et al., 2010), (MOISY, 2008). A dimensão box counting (DBC) pode ser calculada pela equação (3.14) (BACKES; BRUNO, 2008)

$$DBC = -\lim_{r \rightarrow 0} \frac{\log(N(r))}{\log(r)} \quad (4.14)$$

A partir do gráfico de log-log de r por N(r), a curva com inclinação  $\alpha$  é obtida, portanto:

$$DBC = -\alpha \quad (4.15)$$

Neste trabalho, o número de caixas considerado foram as potências de 2, desde 1 até a potência de 2 mais próxima do tamanho da imagem. Portanto, foram consideradas  $r = 1, 2, 4, 8, 16, 32, 64, 128$ . Caso a imagem tivesse dimensões maior que 128,  $r = 256$  também era considerado.

## 4.4 Classificação

Os classificadores utilizados foram Redes Neurais Artificiais (RNA) e a Máquina de Vetores de Suporte (SVM). O SVM foi escolhido por ser o classificador mais comum quando se trata de imagens termográficas da mama na literatura. Ambos foram implementados utilizando-se das toolboxes disponibilizadas pelo Matlab, *Neural Network Toolbox* (para implementação das Redes Neurais) e *Machine Learning Toolbox* (para implementação do SVM). A entrada dos classificadores é uma matriz com as características extraídas das ROI. Como diversas combinações de características foram consideradas, a entrada dos classificadores é variável.

As RNAs consideradas são do tipo *Pattern Recognition Network* que contém uma camada oculta. A função de treinamento utilizada foi *Levenberg-Marquardt backpropagation* que foi escolhida empiricamente. Os critérios de parada da RNA foram 1000 iterações ou gradiente mínimo menor que  $10^{-10}$ . O número de neurônios na camada oculta foi um dos parâmetros consideradas nos testes e serão discutidos no capítulo 5. Já o número de neurônios de entrada depende da combinação de características sendo considerada.

Para o SVM, utilizou-se o modelo *multiclass error-correcting output codes* (ECOC) que possibilita a classificação em mais de duas classes; e a função do Matlab *fitcecoc* que cria e ajusta o modelo para o SVM. As funções de *Kernel* consideradas no SVM foram: Linear, Quadrática, Cúbica, Gaussiana e Sigmoides. Os parâmetros das funções de *kernel*, foram ajustadas dependendo do teste e serão apresentados no capítulo 5. Como considerou-se mais de duas classes como saída do classificador, o tipo de abordagem *one vs one* e *one vs all* é um parâmetro configurável. Ambas abordagens foram consideradas nos testes e serão apresentados no capítulo 5.

## 4.5 Avaliação

As medidas de avaliação consideradas foram de acurácia, especificidade e sensibilidade. Conforme descrito no capítulo 2, acurácia indica a porcentagem de instâncias corretamente classificadas, sensibilidade a porcentagem de instâncias corretamente classificadas como malignas. Como a metodologia utilizada classifica os dados em três classes, consideram-se dois valores para especificidade, que serão apresentados de maneira independente, especificidade normal e especificidade benigna. Isso se deve ao fato de que

tanto pacientes normais quando pacientes com tumores benignos são casos sem a doença, o câncer. Entretanto, como são situações diferentes de ausência da doença, optou-se por calcular a especificidade para cada caso. As expressões 4.16 e 4.17 indicam como foram calculadas a especificidade normal e especificidade benigna respectivamente, onde  $VN_{normal}$  são os Verdadeiros Negativos Normais,  $VN_{benigno}$  os Verdadeiros Negativos Benignos,  $FP_{normal}$  os Falsos Positivos Normais,  $FP_{benigno}$  os Falsos Positivos Benignos.

$$EspecificidadeNormal = \frac{VN_{normal}}{VN_{normal} + FP_{normal}} \quad (4.16)$$

$$EspecificidadeBenigna = \frac{VN_{benigno}}{VN_{benigno} + FP_{benigno}} \quad (4.17)$$

## 5 Experimentos e Resultados

Neste capítulo serão descritos os experimentos realizados e os respectivos resultados obtidos. Os experimentos foram realizados utilizando do software *Matlab 2017*.

### 5.1 Experimentos

#### 5.1.1 Dados de entrada

Os experimentos foram realizados com três tipos de conjunto de dados de entrada diferentes. O primeiro conjunto contemplou as matrizes sem aplicação de nenhum filtro, apenas o pré-processamento necessário para extração das ROI. Nos segundo e terceiro conjuntos foram aplicados filtros. No segundo conjunto foi aplicado o Median Filter, já no terceiro, foi aplicado o Gaussian Filter com  $\sigma = 2$ .

#### 5.1.2 Combinações de características consideradas

Baseados nos quatro grupos de características apresentados no capítulo 3, sete diferentes combinações de características foram consideradas:

- Combinação 1: Todas as 17 características foram consideradas para cada mama, totalizando 34 características de entrada.
- Combinação 2: Foram consideradas as características 1-16 (grupos de medidas estatísticas, medidas estatísticas obtidas a partir da matriz de co-ocorrência e desconsiderando dimensão fractal) para cada mama, totalizando 32 características de entrada.
- Combinação 3: Foram consideradas as 17 características exceto homogeneidade e energia para cada mama. Portanto, 15 características por mama. Totalizando 30 características de entrada.
- Combinação 4: Foram consideradas as características dos grupos de medidas estatísticas (1-9) e dimensão fractal (17). Logo, 10 características por mama. Totalizando 20 características de entrada.
- Combinação 5: Foram consideradas as 17 características exceto homogeneidade, energia e dimensão fractal para cada mama. Consequentemente, 14 características por mama. Totalizando 28 características de entrada.

- Combinação 6: Foram consideradas as características do grupo de medidas estatísticas (1-9). Portanto, 9 características por mama. Totalizando 18 características de entrada.
- Combinação 7: Foram consideradas todas as 17 características para cada mama e ainda os sete primeiros valores do expoente local (que são os sete primeiros valores utilizados para calcular a dimensão box count, ou seja os primeiros sete valores da função de número de caixas pelo tamanho da caixa), somando 24 características por mama. Logo, 48 características de entrada.

Estas combinações foram geradas retirando ou não a dimensão fractal (já que existem artigos que a consideram e outros não); retirando ou não as características próprias (que são homogeneidade e energia); retirando ou não as características de um dos artigos e mantendo as demais para analisar quão relevante são as características de determinado artigo.

### 5.1.3 Parâmetros específicos da RNA

#### 5.1.3.1 Número de neurônios

Inicialmente, foram testadas RNAs com número de neurônios na camada oculta iguais a raiz quadrada do número de neurônios de entrada. Como os resultados não foram satisfatórios, diversos número de neurônios na camada oculta foram testados. Foram eles: 4, 5, 6, 7, 8, 9, 10, 15, 20, 25, 30, 50.

### 5.1.4 Parâmetros específicos do SVM

#### 5.1.4.1 Função Kernel

As funções de Kernel utilizadas foram Linear; Quadrática; Cúbica; Gaussiana, com valores de escala de kernel iguais a 1.5, 5.8 e 23, obtendo gaussiana fina, média ou grossa; sigmoide com inclinação 1.

#### 5.1.4.2 Abordagem classificação multiclasse

Ambas as abordagens one-vs-one e one-vs-all foram consideradas.

### 5.1.5 Validações

Tanto para a RN quanto para o SVM, a validação utilizada foi a separação aleatória de 70% dos dados para treinamento e 30% dos dados para teste. Para o SVM, testou-se ainda o 10-fold-cross-validation. Duas formas de 10-fold-cross-validation foram

consideradas. Na primeira, 10 grupos de 7 pacientes foram formados sendo que os pacientes de cada grupo foram escolhidos de modo aleatório. Já na segunda, também com 10 grupos de 7 pacientes, os pacientes de cada grupo foram escolhidos de modo que cada grupo ficasse o mais heterogêneo e balanceado possível. Em ambos, 9 desses grupos eram utilizados para treinamento e 1 para teste. Esse processo se repetiu 10 vezes, até que todos os grupos fossem considerados para teste.

## 5.2 Resultados

Nesta seção serão apresentados os resultados detalhados dos experimentos que atingiram acurácia significativa (considera-se significativa acurácia maior que 70%). Para os demais casos, serão apenas mencionados quais parâmetros foram considerados.

Cada teste foi repetido 50 vezes, alterando-se apenas o ponto do espaço de solução onde o classificador começa a busca da solução. Apenas o melhor resultado de cada teste foi considerado e reportado nesta seção.

### 5.2.1 Testes com RNA como classificador

- Com 4 neurônios na camada oculta para os dados sem filtros, a combinação 4 resultou em 76.19% de acurácia, 71.4% de especificidade para pacientes normais, 83.3% de especificidade para pacientes com alterações benignas e 75% de sensibilidade maligna. Os demais testes para 4 neurônios não produziram acurácia significativa.
- Com 6 neurônios na camada oculta para os dados sem filtros, a combinação 4 resultou em 71.43% de acurácia, 57.1% de especificidade para pacientes normais, 75% de especificidade para pacientes com alterações benignas e 80% de sensibilidade maligna. Os demais testes para 6 neurônios não produziram acurácia significativa.
- Com 25 neurônios na camada oculta para os dados sem filtros, a combinação 2 e 6 resultaram em 71.43% de acurácia. Para a combinação 2 obteve-se 71.4% de especificidade para pacientes normais, 57.1% de especificidade para pacientes com alterações benignas e 85.7% de sensibilidade maligna. Já para a combinação 6 obteve-se 71.4% de especificidade para pacientes normais, 60% de especificidade para pacientes com alterações benignas e 77.8% de sensibilidade maligna. Os demais testes para 25 neurônios não produziram acurácia significativa.
- Com 50 neurônios na camada oculta para os dados sem filtros, a combinação 7 resultou em 71.43% de acurácia, 75% de especificidade para pacientes normais, 50% de especificidade para pacientes com alterações benignas e 88.9% de sensibilidade maligna. Os demais testes para 50 neurônios não produziram acurácia significativa.

- As sete combinações de características com 5, 7, 8, 9, 10, 15, 20, 30 neurônios na camada oculta para os dados sem filtro não resultaram em acurácia significativa.
- Com 4 neurônios na camada oculta para os dados com o filtro de média, a combinação 7 resultou em 71.43% de acurácia, 42.9% de especificidade para pacientes normais, 60% de especificidade para pacientes com alterações benignas e 100% de sensibilidade maligna. Os demais testes para 4 neurônios não produziram acurácia significativa.
- Com 7 neurônios na camada oculta para os dados com o filtro de média, a combinação 4 resultou em 71.43% de acurácia, 57.1% de especificidade para pacientes normais, 40% de especificidade para pacientes com alterações benignas e 100% de sensibilidade maligna. Os demais testes para 7 neurônios não produziram acurácia significativa.
- Com 9 neurônios na camada oculta para os dados com o filtro de média, a combinação 3 resultou em 71.43% de acurácia, 57.1% de especificidade para pacientes normais, 80% de especificidade para pacientes com alterações benignas e 77.8% de sensibilidade maligna. Os demais testes para 9 neurônios não produziram acurácia significativa.
- Com 30 neurônios na camada oculta para os dados com o filtro de média, a combinações 3 e 5 resultaram em 71.43% de acurácia. Com a combinação 3 obteve-se 40% de especificidade para pacientes normais, 75% de especificidade para pacientes com alterações benignas e 87.5% de sensibilidade maligna. Já com a combinação 5 obteve-se 60% de especificidade para pacientes normais, 71.4% de especificidade para pacientes com alterações benignas e 77.8% de sensibilidade maligna. Os demais testes para 30 neurônios não produziram acurácia significativa.
- As sete combinações de características com 5, 6, 8, 10, 15, 20, 25 e 50 neurônios na camada oculta para os dados com filtro de média não geraram resultados com acurácia significativa.
- Com 7 neurônios na camada oculta para os dados com a aplicação do filtro gaussiano a combinação 3 resultou em 71.43% de acurácia, 71.4% de especificidade para pacientes normais, 57.1% de especificidade para pacientes com alterações benignas e 85.7% de sensibilidade maligna. As demais combinações utilizadas para testes com 7 neurônios não resultaram em acurácia significativa.
- Com 10 neurônios na camada oculta para os dados com a aplicação do filtro gaussiano, a combinação 3 resultou em 71.43% de acurácia, 55.6% de especificidade para pacientes normais, 71.4% de especificidade para pacientes com alterações benignas e

100% de sensibilidade maligna. Os demais testes para 10 neurônios não produziram acurácia significativa.

- Com 15 neurônios na camada oculta para os dados com a aplicação do filtro gaussiano, a combinação 5 resultou em 76.19% de acurácia, 57.1% de especificidade para pacientes normais, 83.3% de especificidade para pacientes com alterações benignas e 87.5% de sensibilidade maligna. Os demais testes com 15 neurônios não proporcionaram acurácia significativa.
- Com 25 neurônios na camada oculta e os dados com a aplicação do filtro gaussiano, as combinações 3 e 7 resultaram em 71.43% de acurácia. A combinação 3 resultou em 40% de especificidade para pacientes normais, 75% de especificidade para pacientes com alterações benignas e 83.3% de sensibilidade maligna. Já com a combinação 7 obteve-se 83.3% de especificidade para pacientes normais, 50% de especificidade para pacientes com alterações benignas e 77.8% de sensibilidade maligna. Os demais testes para 10 neurônios não produziram acurácia significativa.
- As sete combinações de características e 4, 5, 6, 8, 9, 20 neurônios na camada oculta para o filtro gaussiano não produziram acurácia significativa.

A tabela 2 ilustra os experimentos descritos acima considerando a RN como classificador.

### 5.2.2 Testes com SVM como classificador

- Considerando a combinação 3 e os dados sem filtros, a função quadrática como função de kernel e abordagem *one vs one* resultou em 71.42% de acurácia, 42.86% de especificidade para pacientes normais, 71.43% de especificidade para pacientes com alterações benignas e 100% de sensibilidade maligna. Mantendo estes parâmetros para abordagem multiclasse, a combinação e o filtro, as demais funções de kernel não produziram resultados significativos.
- As combinações 1, 2, 4, 5, 6 e 7 e os dados sem filtros para a abordagem *one vs one* e todas as funções kernel testadas não produziram resultados significativos.
- Considerando a combinação 5 e os dados sem filtros, a função cúbica como função de kernel e abordagem *one vs all* produziu 80.95% de acurácia, 83.33% de especificidade para pacientes normais, 85.71% de especificidade para pacientes com alterações benignas e 75% de sensibilidade maligna. Mantendo a abordagem multiclasse, a combinação e o filtro, as demais funções de kernel não produziram resultados significativos.

| Tipo de filtro   | Número de neurônios camada oculta | Combinação | Acurácia (%) | Especificidade Normal (%) | Especificidade Benigna (%) | Sensibilidade (%) |
|------------------|-----------------------------------|------------|--------------|---------------------------|----------------------------|-------------------|
| Sem filtro       | 4                                 | 4          | 76.19        | 71.4                      | 83.3                       | 75                |
|                  | 6                                 | 4          | 71.43        | 57.1                      | 75                         | 80                |
|                  | 25                                | 2          | 71.43        | 71.4                      | 57.1                       | 85.7              |
|                  |                                   | 6          | 71.43        | 71.4                      | 60                         | 77.8              |
|                  | 50                                | 7          | 71.43        | 75                        | 50                         | 88.9              |
| Filtro de Média  | 4                                 | 7          | 71.43        | 42.9                      | 60                         | 100               |
|                  | 7                                 | 4          | 71.43        | 57.1                      | 40                         | 100               |
|                  | 9                                 | 3          | 71.43        | 57.1                      | 80                         | 77.8              |
|                  | 30                                | 3          | 71.43        | 40                        | 75                         | 87.5              |
|                  |                                   | 5          | 71.43        | 60                        | 71.4                       | 77.8              |
| Filtro Gaussiano | 7                                 | 3          | 71.43        | 71.4                      | 57.1                       | 85.7              |
|                  | 10                                | 3          | 71.43        | 55.6                      | 71.4                       | 100               |
|                  | 15                                | 5          | 76.19        | 57.1                      | 83.3                       | 87.5              |
|                  | 25                                | 3          | 71.43        | 40                        | 75                         | 83.3              |
|                  |                                   | 7          | 71.43        | 83.3                      | 50                         | 77.8              |

Tabela 2 – Resultados significativos da RN.

- Considerando a combinação 7 e os dados sem filtros, a função linear como função de kernel e abordagem *one vs all* obteve-se 71.42% de acurácia, 83.33% de especificidade para pacientes normais, 62.5% de especificidade para pacientes com alterações benignas e 71.43% de sensibilidade maligna. Mantendo a abordagem multiclasse, a combinação e o filtro, as demais funções de kernel não produziram resultados significativos.
- As combinações 1, 2, 3, 4 e 6 e os dados sem filtros para a abordagem *one vs all* e todas as funções kernel testadas não produziram resultados significativos.
- Considerando a combinação 1 e os dados com aplicação de filtro de média, a gaussiana média como função de kernel e abordagem *one vs one*, produziu 71.43% de acurácia, 16.66% de especificidade para pacientes normais, 100% de especificidade para pacientes com alterações benignas e 87.5% de sensibilidade maligna. Mantendo a abordagem multiclasse, a combinação e o filtro, as demais funções de kernel não produziram resultados significativos.
- Considerando a combinação 7 e os dados com aplicação de filtro de média, a função quadrática como função de kernel e abordagem *one vs one*, produziu 71.43% de acurácia, 66.66% de especificidade para pacientes normais, 71.43% de especificidade

para pacientes com alterações benignas e 75% de sensibilidade maligna. Mantendo a abordagem multiclasse, a combinação e o filtro, as demais funções de kernel não produziram resultados significativos.

- As combinações 2, 3, 4, 5 e 6 e os dados com o filtro de média para a abordagem *one vs one* e todas as funções kernel testadas não produziram resultados significativos.
- Considerando as combinações 1 e 2 e os dados com aplicação de filtro de média, a gaussiana grossa como função de kernel e abordagem *one vs all* resultaram ambas em 71.43% de acurácia, 50% de especificidade para pacientes normais, 71.43% de especificidade para pacientes com alterações benignas e 87.5% de sensibilidade maligna. Mantendo a abordagem multiclasse e o filtro, tanto para a combinação 1 quanto para a 2, as demais funções de kernel não produziram resultados significativos.
- Considerando a combinação 6 e os dados com aplicação de filtro de média, a função quadrática como função de kernel e abordagem *one vs all*, produziu 71.42% de acurácia, 50% de especificidade para pacientes normais, 57.14% de especificidade para pacientes com alterações benignas e 100% de sensibilidade maligna. Mantendo a abordagem multiclasse, a combinação e o filtro, as demais funções de kernel não produziram resultados significativos.
- Considerando a combinação 7 e os dados com aplicação de filtro de média, a abordagem *one vs all* e as funções de kernel cúbica e gaussiana média como função de kernel produziram respectivamente 71.43% e 76.19% de acurácia. Para o teste com a função cúbica obteve-se 66.66% de especificidade para pacientes normais, 42.86% de especificidade para pacientes com alterações benignas e 100% de sensibilidade maligna. Já o teste com a gaussiana média resultou em 66.66% de especificidade para pacientes normais, 62.5% de especificidade para pacientes com alterações benignas e 100% de sensibilidade maligna. As demais funções de kernel mantendo-se a abordagem multiclasse, a combinação e o filtro, não produziram resultados significativos.
- As combinações 3, 4 e 5 e os dados com o filtro de média para a abordagem *one vs all* e todas as funções kernel testadas não produziram resultados significativos.
- Considerando a combinação 3 e os dados com aplicação de filtro gaussiano, a função linear como função de kernel e abordagem *one vs one*, produziu 71.43% de acurácia, 50% de especificidade para pacientes normais, 85.71% de especificidade para pacientes com alterações benignas e 75% de sensibilidade maligna. Mantendo a abordagem multiclasse, a combinação e o filtro, as demais funções de kernel não produziram resultados significativos.

- As combinações 1, 2, 4, 5, 6 e 7 e os dados com o filtro gaussiano para a abordagem *one vs one* e todas as funções kernel testadas não produziram resultados significativos.
- Considerando a combinação 1 e os dados com aplicação de filtro gaussiano, a gaussiana média como função de kernel e abordagem *one vs all* gerou 71.43% de acurácia, 16.66% de especificidade para pacientes normais, 87.5% de especificidade para pacientes com alterações benignas e 100% de sensibilidade maligna. Mantendo a abordagem multiclasse, a combinação e o filtro, as demais funções de kernel não produziram resultados significativos.
- As combinações 2, 3, 4, 5, 6, 7 e os dados com o filtro gaussiano para a abordagem *one vs all* e todas as funções kernel testadas não produziram resultados significativos.
- Todos os experimentos realizados com 10-fold-cross-validation não produziram resultados significativos.

A tabela 3 sintetiza os experimentos descritos nesta subseção considerando o SVM como classificador.

| Tipo de filtro   | Parâmetros específicos do SVM |                  | Combinação | Acurácia (%) | Especificidade Normal (%) | Especificidade Benigna (%) | Sensibilidade (%) |
|------------------|-------------------------------|------------------|------------|--------------|---------------------------|----------------------------|-------------------|
|                  | Abordagem                     | Função de Kernel |            |              |                           |                            |                   |
| Sem filtro       | one vs one                    | Quadrática       | 3          | 71.43        | 42.86                     | 71.43                      | 100               |
|                  | one vs all                    | Linear           | 7          | 71.42        | 83.33                     | 62.5                       | 71.43             |
|                  |                               | Cúbica           | 5          | 80.95        | 83.33                     | 85.71                      | 75                |
| Filtro de Média  | one vs one                    | Quadrática       | 7          | 71.43        | 66.66                     | 71.43                      | 75                |
|                  |                               | Gaussiana média  | 1          | 71.43        | 16.66                     | 100                        | 87.5              |
|                  | one vs all                    | Quadrática       | 6          | 71.43        | 50                        | 57.14                      | 100               |
|                  |                               | Cúbica           | 7          | 71.43        | 66.66                     | 42.86                      | 100               |
|                  |                               | Gaussiana média  | 7          | 76.19        | 66.66                     | 62.5                       | 100               |
|                  |                               | Gaussiana grossa | 1          | 71.43        | 50                        | 71.43                      | 87.5              |
|                  |                               |                  | 2          | 71.43        | 50                        | 71.43                      | 87.5              |
| Filtro Gaussiano | one vs one                    | Linear           | 3          | 71.43        | 50                        | 85.71                      | 75                |
|                  | one vs all                    | Gaussiana média  | 1          | 71.43        | 16.66                     | 87.5                       | 100               |

Tabela 3 – Resultados significativos do SVM.

### 5.2.3 Comparando os classificadores

A figura 17 ilustra o gráfico comparativo entre os melhores resultados para cada classificador para as combinações que obtiveram resultados significativos em ambos. Desta forma, para as combinações em que mais de um teste produziu resultados significativos, apenas o teste que produziu maior acurácia será representado no gráfico. Percebe-se que o SVM apresentou performance ligeiramente melhor que as RNAs.




Figura 17 – Gráfico comparativo entre os dois classificadores

Com relação ao tempo de análise, percebe-se que o RNA demanda mais tempo para executar todos os testes realizados. Isto se deve as grandes RNAs treinadas e testadas. Redes com menor número de neurônios na camada oculta, por exemplo 4, treinam muito rápido, enquanto redes maiores, com 30 neurônios na camada oculta, demandam bastante tempo. Para os SVM, todos os SVMs treinados e testados tem o mesmo “tamanho” do problema. Considerando uma rodada de experimentos do SVM contendo os testes de todas as funções kernel consideradas, as 7 combinações de características adotadas e as 50 repetições para uma entrada (dados com ou sem filtro). Consequentemente, o número de testes realizados em uma rodada da RNA é 4900. Uma rodada demora algumas horas para executar, um pouco mais 3 horas. Foi portanto, realizado estes experimentos para as três entradas diferentes (com filtro gaussiano, com filtro de mediana e sem filtro). Para as RNA considerando uma rodada de experimentos contendo os testes com todos os números de neurônios na camada oculta considerados, as 7 combinações de características adotadas

e as 50 repetições para uma entrada (dados com ou sem filtro). Consequentemente, o número de testes realizados em uma rodada da RNA é 4200. Uma rodada de experimentos para as RNA demandou em torno de 15 horas. Assim como para o SVM, para as RNA foi também realizado estes experimentos para as três entradas diferentes.

#### 5.2.4 Discussão dos resultados

Um fator que pode ter influenciado negativamente na classificação é a falta de informação da classe de cada mama (esquerda e direita) individualmente, já que apenas a informação da classe da paciente como um todo estava disponível. Em outras palavras, o banco de imagens das pacientes só tem a informação de que a paciente tem ou não alterações benignas ou malignas. O banco não contém a informação de que o câncer está localizado na mama direita por exemplo, ou que há uma alteração benigna na mama esquerda.

Outro ponto que pode ter tido influência negativa nos resultados são as ROIs de tamanhos diferentes para as mamas de uma mesma paciente e entre pacientes diferentes. Como as ROI foram extraídas de modo que apenas a mama fosse considerada, para que isso acontecesse matrizes de tamanhos diferentes foram geradas. Algumas devido a postura da paciente na coleta, outras devido a diferença no tamanho das duas mamas ou ainda para remoção de ruídos nas imagens.

## 6 Conclusão

O uso de imagens termográficas para detecção de câncer de mama é uma técnica promissora para auxiliar no diagnóstico desta doença visto que é uma técnica indolor, que viabiliza a detecção da doença em mamas densas (mamas nas quais outras técnicas apresentam dificuldade de detecção) e livre de radiação. Além disso, proporciona que a doença seja diagnosticada em estágios iniciais, e é uma técnica de baixo custo.

Neste trabalho, uma base de dados com imagens térmicas de 70 pacientes foram analisadas e características foram extraídas para realizar a classificação dessas pacientes em três grupos: normal, com alterações benignas e com alterações malignas (câncer de mama). Com estas características, diversos subconjuntos foram gerados e testados em dois classificadores diferentes: redes neurais artificiais e máquina de vetores de suporte.

Os resultados obtidos se mostraram promissores e confirmaram a premissa de que as imagens termográficas podem auxiliar na detecção do câncer de mama. Com isso, essa técnica se mostra muito atraente para a aplicação em pacientes jovens onde as outras técnicas de diagnóstico se mostram ineficientes. O melhor resultado entre os testes realizados produziu 80.95% de acurácia, 83.33% de especificidade para pacientes normais, 85.71% de especificidade para pacientes com alterações benignas e 75% de sensibilidade maligna e foi obtido pelas características da combinação 5 utilizando o SVM como classificador com a função cúbica como função de kernel e abordagem *one vs all*.

Um dos desafios encontrados no decorrer deste trabalho foi a extração das ROIs. Foi preciso um minucioso processo para extrair as ROIs da forma mais limpa possível. Por ser a primeira etapa do processo, a cada alteração que era feito na extração das ROIs era necessário refazer todas as etapas. Como o processo utilizado foi empírico, cada mama demandava testes diferentes do número de classes do otsu para decidir como a extração ficaria melhor, além dos ajustes manuais que se fizeram necessário.

### 6.1 Trabalhos futuros

Ao final deste trabalho de conclusão de curso, a base de dados foi estruturada e as ROIs de cada imagem estão sistematicamente separadas. Além disso, os scripts escritos em Matlab foram igualmente documentados e estruturados. Desta forma, os próximos alunos (TCC, IC ou Mestrado) que forem trabalhar com este projeto terão o caminho facilitado.

Como trabalhos futuros, propõe-se extrair novas características das imagens buscando melhorar os resultados. Pode-se ainda utilizar algoritmos genéticos para escolha das

características que devem ser consideradas, já que com muitas características é inviável testar todas as combinações delas.

Outra possibilidade é considerar outros tipos de classificadores, como o uso de técnicas de *Deep Learning*, que tem mostrado grande potencial na literatura ou ainda árvores de decisão. Além disso, técnicas para correção da posição podem ser aplicadas, já que a simetria entre as mamas é um fator importante a ser considerado.

Por fim, os resultados obtidos por esse trabalho podem ser comparados com resultados obtidos por outros autores. A técnica proposta aqui também pode ser testada com outras bases de dados de imagens termográficas da mama.

# Referências

- ACHARYA, U. R. et al. Thermography based breast cancer detection using texture features and support vector machine. *Journal of medical systems*, Springer, v. 36, n. 3, p. 1503–1510, 2012. Citado 6 vezes nas páginas 23, 28, 29, 35, 39 e 40.
- ALMEIDA, A. S. de et al. Patologias benignas da mama. *Revista Médica*, Hospital São Vicente de Paulo, v. 26, p. 22–25, 2000. Citado na página 15.
- ARAÚJO, M. Costa de. Utilização de câmera por infravermelho para avaliação de diferentes patologias em clima tropical e uso conjunto de sistemas de banco de dados para detecção de câncer de mama. Universidade Federal de Pernambuco, 2009. Citado 5 vezes nas páginas 11, 12, 15, 16 e 17.
- BACKES, A. R. *Segmentação de imagens*. 2015. Disponível em: <<http://www.facom.ufu.br/~backes/gsi058/Aula09-Segmentacao.pdf>>. Citado 4 vezes nas páginas 6, 18, 19 e 20.
- BACKES, A. R.; BRUNO, O. M. A new approach to estimate fractal dimension of texture images. In: SPRINGER. *International Conference on Image and Signal Processing*. [S.l.], 2008. p. 136–143. Citado 3 vezes nas páginas 20, 21 e 40.
- BORCHARTT, T. Análise de imagens termográficas para a classificação de alterações na mama. *UFF, Niterói*, 2013. Citado 16 vezes nas páginas 6, 11, 12, 15, 16, 17, 18, 21, 22, 23, 25, 26, 27, 35, 36 e 37.
- BORCHARTT, T. B. et al. Breast thermography from an image processing viewpoint: A survey. *Signal Processing*, Elsevier, v. 93, n. 10, p. 2785–2803, 2013. Citado 2 vezes nas páginas 11 e 12.
- CASTRO, F. J. V. Z. Leandro N. de. *Redes Neurais Artificiais*. 2012. Disponível em: <[ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ia006\\_03/topico5\\_03.pdf](ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ia006_03/topico5_03.pdf)>. Citado 3 vezes nas páginas 6, 24 e 25.
- CHAUDHURI, B. B.; SARKAR, N. Texture segmentation using fractal dimension. *IEEE transactions on pattern analysis and machine intelligence*, IEEE, v. 17, n. 1, p. 72–77, 1995. Citado na página 21.
- DENG, G.; CAHILL, L. An adaptive gaussian filter for noise reduction and edge detection. In: IEEE. *Nuclear Science Symposium and Medical Imaging Conference, 1993., 1993 IEEE Conference Record*. [S.l.], 1993. p. 1615–1619. Citado na página 20.
- FARIA, P. N. *QUARTIS, DECIS E PERCENTIS*. 2017. Disponível em: <<https://docs.google.com/viewer?a=v&pid=sites&srcid=ZGVmYXVsdGRvbWFpbnxwcmVudXZlc2ZhcmllhfGd4OjNmNDU2OTYyZl44NzBjOTg>>. Citado na página 38.
- FAWCETT, T. An introduction to roc analysis. *Pattern recognition letters*, Elsevier, v. 27, n. 8, p. 861–874, 2006. Citado na página 26.

- FERLAY I. SOERJOMATARAM, R. D. S. E. C. M. M. R. D. P. D. F. F. B. J. *GLOBOCAN 2012 v1.0, Cancer Incidence and Mortality Worldwide: IARC CancerBase No. 11*. 2012. Disponível em: <<http://globocan.iarc.fr>>. Citado na página 11.
- FORSTER, C. H. Q. *Estatística e Probabilidades*. 2017. Disponível em: <[http://www.comp.ita.br/~forster/CC-226old/02\\_2\\_probabilidades.pdf](http://www.comp.ita.br/~forster/CC-226old/02_2_probabilidades.pdf)>. Citado na página 40.
- HARALICK, R. M.; SHANMUGAM, K. et al. Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, Ieee, n. 6, p. 610–621, 1973. Citado na página 20.
- HAYER, J. *Image Classification-Gray Level Co-Occurrence Matrix (GLCM)*. 2017. Disponível em: <[http://web.pdx.edu/~jduh/courses/Archive/geog481w07/Students/Hayes\\_GreyScaleCoOccurrenceMatrix.pdf](http://web.pdx.edu/~jduh/courses/Archive/geog481w07/Students/Hayes_GreyScaleCoOccurrenceMatrix.pdf)>. Citado na página 39.
- HSU, C.-W.; LIN, C.-J. A comparison of methods for multiclass support vector machines. *IEEE transactions on Neural Networks*, IEEE, v. 13, n. 2, p. 415–425, 2002. Citado na página 22.
- IBARRA-CASTANEDO, C. *Quantitative subsurface defect evaluation by pulsed phase thermography: depth retrieval with the phase*. Tese (Doutorado) — Université Laval, 2005. Citado 3 vezes nas páginas 6, 16 e 17.
- INCA, I. N. de C. *Incidência de Câncer no Brasil - Introdução*. 2016. Disponível em: <<http://www.inca.gov.br/estimativa/2016/index.asp?ID=2>>. Citado na página 11.
- JESUS, E. O.; JR, R. C. A utilização de filtros gaussianos na análise de imagens digitais. *Proceeding Series of the Brazilian Society of Computational and Applied Mathematics*, v. 3, n. 1, 2015. Citado 3 vezes nas páginas 6, 20 e 21.
- KANDLIKAR, S. G. et al. Infrared imaging technology for breast cancer detection—current status, protocols and new directions. *International Journal of Heat and Mass Transfer*, Elsevier, v. 108, p. 2303–2320, 2017. Citado 3 vezes nas páginas 12, 15 e 16.
- KOTSIANTIS, S. B.; ZAHARAKIS, I. D.; PINTELAS, P. E. Machine learning: a review of classification and combining techniques. *Artificial Intelligence Review*, Kluwer Academic Publishers, v. 26, n. 3, p. 159–190, 2006. Citado 5 vezes nas páginas 21, 22, 23, 24 e 25.
- LELES, A. C. Q. et al. Desenvolvimento de procedimento e análise de imagens térmicas para a identificação do câncer de mama. Universidade Federal de Uberlândia, 2015. Citado 6 vezes nas páginas 11, 12, 29, 31, 32 e 40.
- LESSA, V.; MARENGONI, M. Applying artificial neural network for the classification of breast cancer using infrared thermographic images. In: SPRINGER. *International Conference on Computer Vision and Graphics*. [S.l.], 2016. p. 429–438. Citado 8 vezes nas páginas 11, 15, 23, 29, 35, 36, 37 e 38.
- LORENA, A. C.; CARVALHO, A. C. de. Uma introdução às support vector machines. *Revista de Informática Teórica e Aplicada*, v. 14, n. 2, p. 43–67, 2007. Citado 2 vezes nas páginas 6 e 23.

- MADHU, H. et al. Extraction of medically interpretable features for classification of malignancy in breast thermography. In: IEEE. *Engineering in Medicine and Biology Society (EMBC), 2016 IEEE 38th Annual International Conference of the*. [S.l.], 2016. p. 1062–1065. Citado na página 28.
- MATHWORKS. *Matlab*® *entropy*. 2017. Disponível em: <<https://www.mathworks.com/help/images/ref/entropy.html>>. Citado na página 38.
- MATHWORKS. *Matlab*® *graycoprops*. 2017. Disponível em: <<https://www.mathworks.com/help/images/ref/graycoprops.html>>. Citado 2 vezes nas páginas 39 e 40.
- MATHWORKS. *Matlab*® *kurtosis*. 2017. Disponível em: <<https://www.mathworks.com/help/stats/kurtosis.html>>. Citado na página 38.
- MATHWORKS. *Matlab*® *medfilt2*. 2017. Disponível em: <<https://www.mathworks.com/help/images/ref/medfilt2.html>>. Citado na página 19.
- MATHWORKS. *Matlab*® *moment*. 2017. Disponível em: <<https://www.mathworks.com/help/stats/moment.html>>. Citado na página 40.
- MATHWORKS. *Matlab*® *Skewness*. 2017. Disponível em: <<https://www.mathworks.com/help/stats/skewness.html>>. Citado na página 38.
- MATHWORKS. *Matlab*® *Texture Analysis Using the Gray-Level Co-Occurrence Matrix (GLCM)*. 2017. Disponível em: <<https://www.mathworks.com/help/images/texture-analysis-using-the-gray-level-co-occurrence-matrix-glcm.html>>. Citado 2 vezes nas páginas 39 e 40.
- MOISY, F. *Computing a fractal dimension with Matlab: 1D, 2D and 3D Box-counting*. 2008. Disponível em: <<https://www.mathworks.com/matlabcentral/fileexchange/13063-boxcount?focused=5083247&tab=example>>. Citado 2 vezes nas páginas 36 e 40.
- NG, E.-K. A review of thermography as promising non-invasive detection modality for breast tumor. *International Journal of Thermal Sciences*, Elsevier, v. 48, n. 5, p. 849–859, 2009. Citado na página 12.
- OKUNIEWSKI, R. et al. Contour classification in thermographic images for detection of breast cancer. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. *Photonics Applications in Astronomy, Communications, Industry, and High-Energy Physics Experiments 2016*. [S.l.], 2016. p. 100312V–100312V. Citado na página 27.
- OTSU, N. A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, IEEE, v. 9, n. 1, p. 62–66, 1979. Citado 2 vezes nas páginas 6 e 19.
- PAL, N. R.; PAL, S. K. A review on image segmentation techniques. *Pattern recognition*, Elsevier, v. 26, n. 9, p. 1277–1294, 1993. Citado 2 vezes nas páginas 18 e 19.
- PONTI-JR, M. *Cor*. 2012. Disponível em: <[http://wiki.icmc.usp.br/images/a/a1/DIP\\_04\\_Cores.pdf](http://wiki.icmc.usp.br/images/a/a1/DIP_04_Cores.pdf)>. Citado na página 28.
- SUN, T.; NEUVO, Y. Detail-preserving median based filters in image processing. *Pattern Recognition Letters*, Elsevier, v. 15, n. 4, p. 341–347, 1994. Citado 2 vezes nas páginas 19 e 20.

- SYSTEMS, I. F. *Thermal Imaging Cameras for Predictive Maintenance T-Series Unleash the Ultimate Power of FLIR*. 2014. Disponível em: <<http://www.flir.com.br/uploadedFiles/Instruments/Products/T-Series/T-Series-Brochure.pdf>>. Citado 2 vezes nas páginas 6 e 16.
- TAVAKOL, M. E. et al. Analysis of breast thermography using fractal dimension to establish possible difference between malignant and benign patterns. *Journal of Healthcare Engineering*, Hindawi Publishing Corporation, v. 1, n. 1, p. 27–43, 2010. Citado na página 40.
- THOMÉ, A. G. *Processamento de Imagens - Tratamento da Imagem - Filtros*. 2004. Disponível em: <[http://equipe.nce.ufrj.br/thome/p\\_grad/nn\\_img/transp/c4\\_filtros.pdf](http://equipe.nce.ufrj.br/thome/p_grad/nn_img/transp/c4_filtros.pdf)>. Citado 2 vezes nas páginas 19 e 20.
- VALA, M. H. J.; BAXI, A. A review on otsu image segmentation algorithm. *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)*, v. 2, n. 2, p. pp-387, 2013. Citado 2 vezes nas páginas 18 e 19.
- ZHANG, J.; HU, J. Image segmentation based on 2d otsu method with histogram analysis. In: IEEE. *Computer Science and Software Engineering, 2008 International Conference on*. [S.l.], 2008. v. 6, p. 105–108. Citado na página 18.